

Željko Lovrinčević
Zdravko Marić
Edo Rajh*

UDK 332.122 (497.5)
JEL Classification R38, R10
Izvorni znanstveni rad

KAKO OPTIMALNO REGIONALIZIRATI HRVATSKU?

U ovom radu propituje se izbor optimalne varijante statističke regionalizacije Hrvatske na NUTS II razini. Kriteriji za izbor varijante jesu: kriteriji Eurostata o broju stanovnika, maksimalan financijski učinak od pristupa strukturnim fondovima u dugoročnom razdoblju i kriterij homogenosti pojedinih regija kao osnovica za vođenje dugoročne konzistentne politike regionalnog razvitka. Autori propituju osam varijanti statističke regionalizacije i pokazuju što za Hrvatsku izbor svake od njih znači s financijskog i razvojnog stajališta. Ispitane su varijante statističke regionalizacije sa dvije, tri i četiri NUTS II regije i sve dobre i loše strane pojedine varijante. Dalje autori propituju pitanje povezanosti koncepta vođenja regionalne politike (bottom-up i top-down) i adekvatnost pojedine varijante statističke regionalizacije za vođenje regionalne politike u Hrvatskoj.

Ključne riječi: regionalizacija, Hrvatska, strukturni fondovi EU

Uvod

Intenziviranjem procesa širenja Europske unije (EU) razlike u strukturnim karakteristikama i razvijenosti pojedinih članica postaju sve očitije, a to usložnjava vođenje ukupne gospodarske politike. U tom kontekstu, vođenje regionalne poli-

* Ž.Lovrinčević, dr.sc., znanstveni suradnik; Z.Marić, mr.sc., asistent i E.Rajh, dr.sc., znanstveni suradnik, svi u Ekonomskom institutu, Zagreb.

** Ovaj je rad prezentiran na 13.tradicionalnom opatijskom savjetovanju HDE i objavljen u zborniku «Ekonomska politika Hrvatske u 2006.», HDE i Inženjerski biro Zagreb 2005. Za potrebe objavljivanja u *Ekonomskom pregledu*, prvobitni je članak skraćen i izmijenjen.

tike uravnoteženog gospodarskog razvitka i politike poticaja kroz predpristupne i strukturne fondove postaje iznimno važno. Da bi se na razini EU omogućila analiza i utvrđivanje stupnja gospodarskog razvitka neke zemlje odnosno regije, formuliranje i provođenje regionalne politike i praćenje mjera i učinaka tih mjera na razvitak, bilo je potrebno stvoriti usklađeni sustav statističkih regija koji će omogućiti prikupljanje i obradu usporedivih podataka.

Nomenklatura prostornih jedinica za statistiku (NUTS) hijerarhijski je sustav klasifikacije teritorija EU unutar nacionalnih, regionalnih ili administrativnih granica zemlje. NUTS se stoga koristi kao statističkom osnovicom za prikupljanje, razvitak, usklađivanje i promicanje regionalne statistike unutar EU. Sadašnji sustav dijeli teritorij EU, a time i teritorij svake zemlje članice, na pet razina; tri osnovne razine NUTS I, NUTS II i NUTS III, te na još dvije dodatne razine LAU 1 i LAU 2 (prije NUTS IV i NUTS V, LAU – Local Administrative Units). Rezultat je takvog sustava podjele formiranje regija, regionalnih jedinica i subregionalnih jedinica.

Prilikom uspostave Nomenklature prostornih jedinica za statistiku (NUTS) potrebno je pored osnovnog kriterija broja stanovnika, uvažiti kriterije homogenosti statističkih jedinica, prirodno-geografske raznolikosti, povijesne tradicije i potencijalno i neke druge dodatne kriterije.

Republika Hrvatska kao zemlja kandidat utvrđuje svoje tzv. statističke regije koje će danom ulaska u EU postati NUTS regije. Postojeća administrativna podjela Republike Hrvatske udovoljava kriterijima Eurostata o statističkoj regionalizaciji na razinama NUTS I (cijela Hrvatska), NUTS III (županije) i LAU 2 (općine i gradovi).¹ Za NUTS II razinu u Hrvatskoj ne postoji odgovarajuća administrativna podjela. U ovom članku prikazani su rezultati detaljne analize potencijalnih varijanti statističke regionalizacije Hrvatske na NUTS II razini sa tri osnovna stajališta.

Osnovna je hipoteza ovog rada formulirana na slijedeći način: moguće je izabrati optimalnu varijantu statističke regionalizacije Hrvatske na NUTS II razini koja će zadovoljiti sva tri postavljena kriterija - kriterij Eurostata o broju stanovnika, maksimalan financijski učinak od pristupa strukturnim fondovima u dugoročnom razdoblju i kriterij homogenosti pojedinih regija.

To je ponajprije udovoljavanje kriterijima EU za izradu statističkih jedinica. Potom slijedi propitivanje financijskog stajališta pojedine varijante statističke regionalizacije Hrvatske na osnovi potencijalnih sredstava iz strukturnih fondova u dugoročnijem razdoblju. Na kraju, valja sa stajališta nacionalnih interesa uvažiti kriterij homogenosti pojedine varijante jer ona čini osnovicu za vođenje konzistentne nacionalne regionalne politike. Regionalna politika može se relativno

¹ Podrobnije vidjeti u studiji Državnog zavoda za statistiku "Metodologija za uvođenje nacionalne klasifikacije prostornih jedinica za statistiku u statistički sustav Republike Hrvatske", Zagreb, travanj 2005.

uspješno voditi i u nehomogenim regijama. Uvjet je postojanje izraženo kvalitetne koordinacije nositelja razvojne politike na državnoj i na razini regionalne i lokalne samouprave i visoke kvalitete javne uprave na najnižoj razini (općine) koja je sposobna osmisliti, koordinirati i nadgledati razvojne projekte (bottom up pristup). U današnjim uvjetima je to u određenoj mjeri nerealno očekivati od tih najnižih administrativnih jedinica u Hrvatskoj, pa je homogenost regija značajna za potrebe vođenja kombinirane top down i bottom up politike.

U tom je kontekstu propitano osam varijanti regionalizacije Hrvatske s brojnih stajališta, te su analizirani kriteriji za izbor optimalne varijante. Analiza uključuje i stari prijedlog statističke regionalizacije na četiri regije, koji je DZS na početku 2005. uputio Eurostatu, a pokazuje očite slabosti u odnosu na neke druge varijante statističke regionalne podjele Hrvatske na NUTS II regije, osobito s financijskog stajališta i stajališta homogenosti koji su iznimno važni.

Članak se sastoji od pet dijelova. Nakon uvodnih razmatranja, u drugom dijelu propituju se uloga regionalne politike EU i uloga predpristupnih i strukturnih fondova, kako danas, tako i u nadolazećem razdoblju. Analiza strukture NUTS II regija EU, a posebno NUTS II regija novih deset zemalja članica (NMS10) prikazana je u trećem dijelu. Treći dio sadrži i simulacije učinaka osam varijanti statističke regionalizacije Hrvatske. Odvojeno su podrobno prikazani brojni ekonomski pokazatelji i učinci na potencijalna sredstva iz strukturnih fondova i na razinu homogenosti za potrebe vođenja konzistentne regionalne politike. Korištena je tehnika cluster analize. U određivanju optimalne varijante zbog dugog vremenskog razdoblja projekcije (2015. godina), postoje i određene nepoznanice poput datuma ulaska Rumunjske i Bugarske u EU, odnosno pristupanje Turske, koja svojim brojem stanovnika mijenja razine razvijenosti mjerene BDP-om po stanovniku po paritetu kupovne snage. U četvrtom dijelu prikazani su zbirni rezultati analize prednosti i nedostataka svih ponuđenih varijanti statističke regionalizacije Hrvatske na NUTS II razini s obrazloženjem. Peti je dio zaključni.

Regionalna politika EU, povijest i kriteriji NUTS

Hrvatskoj je dobivanjem statusa kandidata za članstvo u EU omogućen pristup predpristupnim fondovima EU. Od 2007. godine, kad započinje nov proračunski ciklus, Hrvatska će moći povlačiti sredstva iz novog predpristupnog fonda IPA (Instrument for Pre-Accession Assistance), koji će zamijeniti postojeće predpristupne fondove PHARE, ISPA i SAPARD.

O visini rezerviranih sredstava odlučuje Europska komisija, a povlačenje sredstava ovisi o kvaliteti programa koje zemlja kandidat predlaže za financiranje iz

predpristupnih fondova EU. Iskustva novih zemalja članica pokazuju da je pojedina zemlja uspjela povući od 10% do 50% raspoloživih sredstava iz predpristupnih fondova. No, mnogo je značajniji položaj Hrvatske u srednjoročnom razdoblju u odnosu na strukturne fondove koji se tiču zemalja članica EU.

Kad se govori o strukturnim fondovima EU u razdoblju 2007.-2013. godine, valja reći da se novom regulativom Europske komisije² predlažu ciljevi i kriteriji pružanja potpore iz strukturnih fondova EU. O raspodjeli sredstava strukturnih fondova po zemljama članicama odlučuje Europska komisija. Podlogu za donošenje odluke čine statistički pokazatelji (npr. bruto domaći proizvod po stanovniku, stopa nezaposlenosti, stanovništvo itd.). Korisnici sredstava strukturnih fondova nisu države, već su to NUTS regije. Ključni kriterij u provođenju politike strukturnih fondova i definiranju prava na povlačenje sredstava (eligibility) imaju pokazatelji regionalne statistike na NUTS II razini.

U proširenoj EU sa 25 zemalja članica, 27% stanovništva (123 milijuna) živi u regijama kojih je BDP po stanovniku niži od 75% prosjeka EU25. Od tih 123 milijuna ljudi, 72 milijuna ljudi živi u starim zemljama članicama EU15. Jaz između najrazvijenijih i najmanje razvijenih regija u EU25 udvostručen je u odnosu na situaciju prije proširenja. Usporavanje ekonomskog rasta EU s jedne strane, i ostvarenje strateških razvojnih ciljeva zasnovanih na Lisabonskoj konferenciji 2000. godine s druge strane, zahtijevaju promjene regionalne razvojne politike EU. U okviru općeg cilja veće kohezije EU definirana su tri nova razvojna cilja:

1. konvergencija,
2. regionalna konkurentnost i zapošljavanje,
3. europska teritorijalna suradnja.

Cilj "konvergencija" obuhvaća tri skupine regija/zemalja koje mogu aplicirati za financiranje, a to su:

a) Prije svega slabije razvijene regije razine NUTS II svih zemalja EU25, čiji je BDP p.c. (per capita – po stanovniku) niži od 75% prosjeka BDP p.c. EU25. Pri tome se BDP iskazuje po paritetu kupovne snage, a prosjek se računa za posljednje tri godine.

b) Budući da se proširenjem EU prosječan BDP po stanovniku smanjio, neke su slabije razvijene regije NUTS II razine zemalja starih članica EU15 izašle iz programa strukturne pomoći, jer njihov BDP p.c. nije više niži od prosjeka EU25. Budući da u tim regijama nije ostvaren objektivan napredak u razini razvijenosti, već se radi o tzv. "statističkom učinku proširenja", regijama zemalja članica EU15

² Council Regulation on laying down general provisions on the European Regional Development Fund, the European Social Fund and the Cohesion Fund, COM (2004) 492 final, Bruxelles, 14.07.2004.

kojih je BDP p.c. niži od 75% prosjeka EU15 i dalje će biti omogućen pristup financiranju iz strukturnih fondova u okviru cilja "konvergencija". Pritom se BDP iskazuje po paritetu kupovne snage, a prosjek se računa za posljednje tri godine.

c) Treću skupinu čine pojedine zemlje članice, kojih je bruto nacionalni dohodak (*Gross National Income, GNI*) po paritetu kupovne snage niži od 90% prosjeka EU25. Pritom se GNI iskazuje po paritetu kupovne snage, a prosjek se računa za posljednje tri godine.

d) Četvrta skupina regija koje se mogu koristiti financijama iz ERDF za ostvarivanje cilja "konvergencija", kao i cilja "regionalna konkurentnost i zapošljavanje" su prekomorske regije EU.³

Cilj "konvergencija" za regije NUTS II razine iz skupina a) i b) bit će financirane sredstvima strukturnih fondova ERDF (European Regional Development Fund) i ESF (European Social Fund). Za zemlje koje ispunjavaju kriterij c), financiranje cilja "konvergencija" bit će osigurano sredstvima Kohezijskog fonda koji osigurava sredstva pretežito za nove zemlje članice EU, kojih je bruto nacionalni dohodak po stanovniku za 10% niži od prosjeka EU25.⁴

U okviru cilja "regionalna konkurentnost i zapošljavanje" bit će financirane dvije vrste programa - regionalni i programi socijalne kohezije. Regionalni će programi biti financirani isključivo preko ERDF radi poticanja gospodarskih promjena u industrijskim, urbanim i ruralnim područjima EU, a u cilju jačanja konkurentnosti pojedinih regija EU.

Cilj "europska regionalna suradnja" nastavlja se na osnovu iskustava INTERREG inicijative. Ostvarenje cilja bit će financirano isključivo iz sredstava ERDF, na tri područja suradnje: na području prekogranične suradnje, međunarodne regionalne suradnje (između regija EU i susjednih trećih zemalja) i međuregionalne suradnje unutar EU.

U razdoblju 2007.-2013. na snazi će biti pojednostavnjen decentralizirani postupak korištenja strukturne pomoći u EU. Ukupno će financiranje biti obavljeno iz tri strukturna fonda, umjesto sadašnjih šest: iz ERDF, ESF i iz Kohezijskog fonda. Ukupno planirana sredstva strukturnih fondova povećana su u odnosu na prethodno proračunsko razdoblje, imajući u vidu proširenje EU na sadašnjih 25 zemalja članica, ali i ulazak Bugarske i Rumunjske za koje se očekuje da će u razdoblju 2007.-2013. imati pravo korištenja sredstava strukturnih fondova kao punopravne članice EU²⁷. **Ukupno planirana sredstva u proračunu fondova, prema preliminarnom prijedlogu, za razdoblje 2007.-2013. godine iznose bruto 373,9 milijardi EUR.** Neto raspoloživi iznos za tri strukturna fonda po odbitku

³ Gvadalupa, Francuska Gvajana, Martinik, Reunion, Azori, Madeira, Kanarski otoci.

⁴ Podrobnije o analizi utjecaja sredstava strukturnih fondova EU na regije kohezijskih zemalja vidjeti npr. u Farrel (2004).

37,8 milijardi EUR, koje će biti izdvojene za instrumente financiranja ribarstva i poljoprivrede iz Kohezijskog fonda, bit će **336,1 milijardu EUR**.

Predložena raspodjela sredstava strukturnih fondova na tri nova cilja kohezijske politike EU i ostvarenje prioriteta unutar tih ciljeva, prikazana je u Tablici 1. Ukupni su iznosi i udjeli indikativni, jednako kao i kriteriji sukladno s kojima će biti raspodjeljena sredstva za one regionalne jedinice koje ispunjavaju uvjete za dobivanje financijske potpore, odnosno koji će biti uvaženi prilikom izračunavanja odgovarajućeg dijela sredstava raspoloživih za pojedinu zemlju članicu.

Tablica 1.

**PLANIRANO FINANCIRANJE KOHEZIJSKIH CILJEVA
IZ STRUKTURNIH FONDOVA EU, 2007.-2013.**

Ciljevi	Udio u ukupnom proračunu, %	Udio u pojedinom cilju, %	Milijarde EUR	Kriteriji raspodjele po zemljama
Konvergenција (convergence)	78,54	100	264,047	
a) NUTS II BDP p.c. PPS<75% EU25		67,34	177,809	broj stanovnika, regionalni i nacionalni napredak, nezaposlenost
b) NUTS II BDP p.c. PPS< 75% EU15		8,38	22,127	broj stanovnika, regionalni i nacionalni napredak, nezaposlenost
c) države GNI p.c. PPS< 90% EU25		23,86	63,002	broj stanovnika, napredak u nacionalnom razvitku u odnosu na prethodno razdoblje, površina
d) prekomorske regije		0,42	1,109	broj stanovnika
Regionalna konkurentnost i zapošljavanje (competitiveness and employment regions)	17,22	100	57,893	
NUTS I i NUTS II koje ne zadovoljavaju kriterij cilja konvergenција		83,44	48,306	broj stanovnika, regionalni napredak, nezaposlenost, stopa zaposlenosti, gustoća naseljenosti

NUTS II koje ne zadovoljavaju kriterij cilja konvergencija, a bile su pokrivene Ciljem 1 u 2006.	16,56	9,587	broj stanovnika, regionalni i nacionalni napredak, nezaposlenost
EU teritorijalna suradnja	3,94	100	13,246
prekogranična suradnja NUTS III	47,73	6,322	broj stanovnika
međunarodna regionalna suradnja	47,73	6,322	broj stanovnika
međuregionalna suradnja	4,54	0,601	
Ukupno	100	336,194	

Izvor: Council Regulation on laying down general provisions on the European Regional Development Fund, the European Social Fund and the Cohesion Fund, COM (2004) 492 final, Bruxelles, 14.07.2004.

Iz Tablice 1 vidi se da će čak 78,5% ukupno raspoloživih sredstava u idućem sedmogodišnjem proračunskom razdoblju EU biti namijenjeno financiranju cilja “konvergencija” (oko 265 milijardi EUR), od čega većina (177 milijardi EUR) za financiranje NUTS II regija kojih je BDP po stanovniku niži od 75% prosjeka EU25. Broj ljudi koji će živjeti u područjima s razinom razvijenosti nižom od 75% BDP p.c. PPS EU25 u NUTS II regijama jednak je 123 milijuna danas, plus Rumunjska (21,8 milijuna) i Bugarska (6,5 milijuna), odnosno 151,3 milijuna ljudi 2010. godine. Zbog predviđenih sredstava u okviru tzv. konvergencije (264 milijarde EUR) umanjene za prekomorske regije (1,1 milijarda EUR), znači da će prosječno po stanovniku biti raspoloživo **oko 248 EUR godišnje**, za one regije gdje je **BDP p.c. PPS niži od 75% prosjeka EU27**. To je, naravno, gornji iznos koji ovisi o kvaliteti programa i infrastrukturnog kapaciteta u povlačenju sredstava.

Kao što se vidi iz Tablice 1, dodatnih će 57,9 milijardi EUR odnosno 13,2 milijarde EUR biti raspoloživo za stanovnike regija koje imaju razinu razvijenosti višu od 75% prosjeka BDP p.c PPS EU27 u okviru cilja regionalne konkurentnosti i zapošljavanja, odnosno EU teritorijalne suradnje. To je iznos od oko 30 EUR godišnje po stanovniku.

Postojanje financijskog plana za razdoblje 2007.-2013., uz postojeću strukturu NUTS II regija, pruža mogućnost izračuna potencijalno raspoloživih sredstava za kandidiranje programa financiranih iz europskih strukturnih fondova i za Hrvatsku nakon 2010. Razina potencijalno raspoloživih sredstava za povlačenje ovisit će o izabranoj varijanti statističke regionalizacije Hrvatske i jedan je od osnovnih kriterija za odabir ponajbolje varijante regionalizacije na NUTS II razini.

Regionalni pokazatelji razvitka na NUTS II razini – analiza različitih varijanti statističke regionalizacije Hrvatske

Metodološka osnovica za gospodarske projekcije

U ovom poglavlju prikazane su projekcije gospodarskog rasta hrvatskih NUTS II regija, odnosno razina razvijenosti mjerena BDP p.c PPS u odnosu na EU25 (EU27), koje valja očekivati u svakoj od osam analiziranih varijanti statističke regionalizacije Hrvatske na NUTS II razini. Takva projekcija treba dati odgovor na pitanje o tome koji su očekivani učinci od potencijalnih sredstava iz europskih strukturnih fondova u dugoročnom razdoblju. Ovo poglavlje također obuhvaća i analizu gospodarske, demografske i socijalne homogenosti⁵ u pojedinoj varijanti statističke NUTS II regionalizacije Hrvatske. Ta bi analiza morala dati odgovor na drugi važan kriterij, a to je homogenost kao osnovni preduvjet za dugoročno vođenje konzistentne regionalne politike.

Projekcije razine BDP po stanovniku hrvatskih regija zasnivaju se na slijedećim podacima:

1. uočenoj konvergenciji/divergenciji regija tranzicijskih zemalja novih članica EU,
2. stopama rasta BDP po djelatnostima NACE klasifikacije u EU15 i NMS10,
3. sadašnjoj gospodarskoj strukturi hrvatskih regija,
4. obvezi uključivanja sive ekonomije u obračun BDP novih zemalja članica EU (Exhaustiveness Project), koju Hrvatska još nije ispunila, a sve su druge nove članice EU25 to učinile.⁶

Regionalna kretanja u NMS10 zemalja i EU15

NUTS II regije zemalja novih članica (NMS10⁷) mogu se prema kriteriju BDP, zaposlenosti, nezaposlenosti i stanovništva podijeliti na osnovi procesa konvergencije prema EU15, u četiri skupine⁸:

⁵ Više o značenju homogenosti za vođenje regionalne politike vidjeti u Marinović-Uzelac (2001) i Rašić (2005).

⁶ Više o obvezi i metodologiji uključivanja sive ekonomije u službeni BDP novih zemalja članica vidjeti u studiji Ekonomskog instituta, Zagreb i DZS "Uvođenje i primjena sustava nacionalnih računa", istraživanja za 2005. godinu.

⁷ Cipar, Češka, Estonija, Latvija, Litva, Mađarska, Malta, Poljska, Slovačka i Slovenija.

⁸ Reveu elargissement br. 75, 11. travnja 2005.

- regije sa snažnim potencijalom konvergencije,
- regije s umjerenim potencijalom konvergencije,
- regije s umjerenim rizikom divergencije,
- regije s visokim rizikom divergencije.

U razdoblju 1995.-2002. godine, od ukupno 41 regije NUTS II razine zemalja novih članica trideset jedna je zabilježila smanjivanje razlike prema prosjeku EU25 prema pokazatelju BDP p.c PPS. U prosjeku je godišnja stopa rasta BDP p.c PPS iznosila za ovu skupinu zemalja 5,6%, a EU15 zabilježio je prosječan godišnji rast od 4%.

Šest od deset NUTS II regija NMS koje su rasle sporije od EU25 prosjeka nalaze se u Češkoj, koja je, uz Cipar, jedina zemlja sa zabilježenim sporijim rastom od prosjeka starih članica EU15. U prvu skupinu NUTS II regija sa **snažnim potencijalom konvergencije** mogle bi se svrstati tri Baltičke zemlje (Estonija, Litva i Latvija) i Slovenija, koje predstavljaju mala gospodarstva i klasificirane su kao jedna NUTS II regija, iako su države. Zatim tu ubrajamo tri mađarske regije koje su locirane na potezu Beč – Budimpešta, i na istoku regiju oko Debrecena i dvije slovačke regije: Bratislava i Istočna Slovačka (Košice). Sve te regije karakterizira visoka stopa rasta BDP, smanjenje broja nezaposlenih, blago smanjenje ili porast broja zaposlenih i povoljna demografska kretanja (porast ili blago smanjenje broja stanovnika).

NUTS II regije s **umjerenim potencijalom konvergencije** karakterizira relativno dinamičan rast (prosječna stopa rasta BDP po stanovniku prema PPS više od 4,5%), ali u uvjetima blago rastuće nezaposlenosti ili blago padajuće zaposlenosti. U tim se regijama očekuje da će pozitivne sastavnice u procesu “kreativne destrukcije” nadvladati negativne i u nastavku bi mogao biti zabilježen pozitivan pomak u konvergenciji prema prosjeku EU25.

U NUTS II regijama s **umjerenim rizikom divergencije**, koje se, uz Cipar, uglavnom nalaze uzduž granice Češke i Njemačke, zabilježen je sporiji rast (niži ili oko prosjeka NMS10), ali uz porast stope nezaposlenosti. U tu su skupinu svrstane i regije sa sporijim rastom BDP, ali uz smanjenje stope nezaposlenosti (Plzen, Karl. Vary).

U skupinu regija s **visokim rizikom divergencije** svrstano je 11 NUTS II regija, u kojima je prosječan godišnji porast BDP po stanovniku prema PPS za više od jedne standardne devijacije niži od prosjeka NMS10. Osim sporog rasta, ove regije karakterizira i porast broja nezaposlenih a to uz pad broja zaposlenih dovodi do značajnog porasta stope nezaposlenosti. Regije u toj skupini imaju i najlošija demografska kretanja (pad broja stanovnika).

Klasifikacija NUTS II regija prema potencijalu gospodarskog rasta prikazana je u Tablici 2. Napominjemo da je, radi lakšeg lociranja pojedinih regija na zemljopisnoj karti, naveden središnji grad pojedine regije, a ne službeni naziv regije.

Tablica 2.

PROSJEČNE GODIŠNJE STOPE RASTA BDP P.C. PPS (1995.-2002.),
NEZAPOSLENOSTI (1999.-2003.), ZAPOSLENOSTI (1999.-2003.)
I STANOVNIŠTVA (1995.-2002.)

Regije NUTS II razine	Rast BDP	Nezaposlenost	Zaposlenost	Stanovništvo
<i>regije sa snažnim potencijalom konvergencija</i>				
Budimpešta	8,1	-5,1	0,6	-0,3
Talinn	7,8	-2,9	0,5	-0,7
Riga	7,7	-5,3	0,7	-0,8
Bratislava	7,4	-0,8	-0,1	-0,4
Vilnius	7,1	-1,5	-0,8	-0,6
Gyor	6,5	0,9	0,2	0,0
Tatabanya	6,1	-5,5	1,2	0,0
Košice	6,0	0,5	0,4	0,3
Ljubljana	5,5	-2,0	0,3	0,1
Debrecen	5,1	-7,8	1,5	0,1
<i>regije s umjerenim potencijalom konvergencija</i>				
Varšava	8,2	9,8	-3,0	0,2
Prag	6,5	1,0	-0,4	-0,6
Poznan	6,4	11,8	-0,3	0,1
Zilina	6,2	2,0	-0,1	0,0
Trnava	5,2	2,3	0,6	-0,1
La Valette	5,0	0,5	0,6	0,8
Pecs	4,9	-1,0	0,5	-0,1
Miskolc	4,6	-3,5	1,4	-0,1
Kladno	4,5	-8,3	0,9	0,2
<i>regije s umjerenim rizikom divergencije</i>				
Bialystok	5,8	7,7	-3,2	-0,1
Wroclaw	5,7	11,9	-4,4	-0,3
Kielce	5,6	7,7	-2,1	-0,3
Lodz	5,5	10,1	-1,1	-0,4
Krakow	5,4	14,1	-1,3	0,2
Gdansk	5,4	13,1	-2,1	0,1
Nikosia	3,8	-5,0	3,2	1,1
Jihailiva	3,6	-2,8	-0,2	-0,2
Hradec	3,4	-3,3	-0,1	-0,1
Plzen	3,1	-4,0	0,1	-0,1
Karl. Vary	1,5	-3,7	0,1	-0,1
<i>regije s visokim rizikom divergencije</i>				
Szczecin	5,0	5,2	-2,9	-0,1
Olsztyn	4,9	4,2	-1,0	-0,2
Rzeszow	4,8	7,0	-0,8	0,0
Bydgoszcz	4,6	10,6	-0,5	-0,1
Katowice	4,4	12,7	-2,1	-0,4
Zielona G.	4,4	7,8	-0,7	-0,3
Lublin	4,1	8,5	-0,5	-0,1
Szeged	3,9	2,3	-0,4	0,0
Opole	3,4	5,4	-3,1	-0,3
Brno	2,6	-2,2	-0,2	-0,1
Ostrava	2,2	2,5	-0,6	-0,3

Izvor: Revue elargissement br. 75, 11. travnja 2005.

Važno je napomenuti da je u skupini zemalja novih članica EU u razdoblju 1995.-2002. došlo do **pogoršanja omjera** između najrazvijenije i najnerazvijenije regije (Tablica 3).⁹

Tablica 3.

OMJER IZMEĐU NUTS II REGIJE S NAJVIŠOM I NAJNIŽOM
 VRIJEDNOŠĆU BDP P.C. PPS PO ZEMLJAMA, 1995.-2002.

Zemlja	1995.	1997.	1999.	2001.	2002.
NMS					
Češka	2,4	2,5	2,6	2,9	2,9
Mađarska	2,0	2,2	2,4	2,4	2,6
Poljska	1,7	1,8	2,1	2,1	2,2
Slovačka	2,8	2,8	2,9	3,0	3,1
EU15					
Belgija	3,0	3,1	3,2	3,2	3,1
Njemačka	2,9	2,9	2,8	2,9	2,8
Grčka	2,1	1,9	1,8	1,9	1,9
Španjolska	2,1	2,1	2,1	2,1	2,1
Francuska	3,0	3,0	2,9	3,0	3,1
Irska	1,4	1,5	1,5	1,5	1,6
Italija	2,4	2,3	2,3	2,3	2,4
Nizozemska	1,6	1,7	1,7	1,7	1,7
Austrija	2,3	2,2	2,2	2,2	2,1
Portugal	1,9	2,0	1,9	1,9	1,8
Finska	1,6	1,7	1,9	1,9	1,9
Švedska	1,5	1,6	1,6	1,6	1,6
Velika Britanija	4,1	4,2	4,4	4,3	4,3

Izvor: Eurostat.

Najveće razlike u razvijenosti regija zamjetne su u Slovačkoj i Češkoj, a relativno je najbrži porast nejednakosti zabilježen u Mađarskoj. Obično je bila riječ o iznadprosječnom ubrzanom rastu regija koju čine glavni grad i uža ili šira okolica. Taj fenomen nastaje zbog takozvanog **“gateway”** učinka, gdje gotovo svi glavni gradovi tranzicijskih zemalja predstavljaju ulazna vrata za strane investitore u zemlju. To podrazumijeva golemu koncentraciju primarno financijskih, teleko-

⁹ Malta, Cipar, Estonija, Latvija, Litva i Slovenija istovremeno su jedine regije na NUTS II razinama.

munikacijskih, informatičkih i drugih logističkih djelatnosti u glavnim gradovima. Taj je proces vidljiv i on postoji unatoč nastojanjima vlada tranzicijskih zemalja da imaju što uravnoteženiji regionalni razvitak.

Sa druge strane, u zemljama starim članicama (EU15) zamjetno je zaustavljanje trenda dalje centralizacije gospodarske aktivnosti u najrazvijenijim područjima. Primarni je razlog za takvo zaustavljanje trenda upravo osmišljena politika uravnoteženog regionalnog razvitka poduprta europskim strukturnim fondovima. Stoga i u NMS skupini, odnosno u zemljama kandidatima za članstvo u EU, valja tek u dugoročnom razdoblju očekivati zaustavljanje trenda centralizacije gospodarske aktivnosti i naglašeniji uravnoteženiji regionalni razvitak.

Projekcije gospodarskog rasta i očekivane promjene regionalne gospodarske strukture u Hrvatskoj do 2015. godine

U ovom je dijelu analizirana dinamika promjene gospodarske strukture europskih NUTS II regija, kao osnovica za projekciju dinamike strukture pojedinih varijanti statističke regionalizacije Hrvatske na NUTS II razini. Posebna pozornost posvećena je činjenici prelaska, odnosno ostajanja na razini nižoj od 75% razine prosjeka BDP p.c. po PPS EU25 u razdoblju do 2015. godine.

U Tablici 4 prikazane su stope rasta gospodarstava za zemlje članice EU25 prema djelatnostima NKD klasifikacije. Vidi se da je u cijelom razdoblju BDP novih članica u prosjeku rastao brže od BDP starih članica, što je i očekivano imajući u vidu da je s približavanjem EU započeo intenzivan proces realne konvergencije i postoji učinak tzv. niske osnovice. U prosjeku je realan rast novih članica bio brži za oko 0,87 postotnih bodova. No, analizirajući rast po djelatnostima, može se uočiti da nove članice bilježe najbrži prosječan rast u sektoru trgovine, hotela i restorana i prijevoza (G, H i I) i poslovnih i financijskih usluga (J i K). Industrija (C, D i E) i građevinarstvo (F) rastu nešto brže od ukupnog BDP, sa zamjetnim oscilacijama kroz godine, a djelatnosti javne uprave, obrazovanja, zdravstva i ostalih osobnih i društvenih usluga (L, M, N i O) rastu sporije od prosjeka. Najsporiji rast (u nekim godinama i realan pad) zabilježen je u poljoprivredi i ribarstvu (A i B).

Takva kretanja upućuju na **zaključak da zatečena gospodarska struktura u velikoj mjeri određuje i potencijal rasta pojedinih NUTS II regija**. Povoljnija sadašnja gospodarska struktura (veći udio propulzivnih uslužnih sektora, a manji udio poljoprivrede i državnih usluga) osigurava i ostvarenje viših stopa rasta u budućem srednjoročnom razdoblju. Upravo je to utjecalo na dalje povećanje razlika između razvijenih i manje razvijenih regija u NMS skupini zemalja, jer je najpovoljnija gospodarska struktura zabilježena u najrazvijenijim regijama.

STOPE REALNOG RASTA BDP EU25 PO DJELATNOSTIMA NACE
KLASIFIKACIJE, 2000.-2003.

[illegible]

IT	3,0	1,8	0,4	0,3	-2,9	-0,5	-3,9	-5,7	2,3	-0,2	-0,3	-1,0	3,5	3,1	2,5	2,5	5,6	3,5	-0,1	0,0	5,1	2,8	1,8	1,2	1,0	2,1	1,2	0,6
CY	5,0	4,1	2,1	1,9	-5,9	3,8	5,4	4,5	3,4	0,3	0,4	0,6	-1,2	4,0	4,7	4,4	8,8	5,2	-0,3	-0,7	6,4	5,5	3,5	2,7	3,6	3,1	4,0	4,3
LV	6,9	8,0	6,4	7,5	11,5	6,4	4,4	1,0	4,4	9,7	8,1	7,8	8,2	6,1	10,8	13,7	8,2	10,2	8,1	10,4	12,3	12,2	5,5	4,3	1,4	2,0	2,8	3,3
LT	3,9	6,4	6,8	9,7	6,4	-4,6	8,2	2,2	5,4	13,9	4,6	15,8	-18,2	7,4	12,7	22,0	6,7	8,1	9,3	9,1	5,0	5,6	6,6	6,2	4,3	-0,9	2,9	2,4
LU	9,0	1,5	2,5	2,9	-7,2	-15,1	0,1	-2,3	6,9	1,0	2,0	2,6	5,1	8,0	5,3	4,3	9,4	6,3	3,3	3,4	9,4	-0,5	2,5	1,7	2,9	4,7	1,0	3,6
HU	5,2	3,8	3,5	3,0	-7,4	23,4	-12,1	-4,0	6,4	0,4	1,3	5,4	19,2	5,2	12,9	1,2	0,8	5,0	4,7	4,3	8,3	4,4	6,3	-1,3	3,3	3,4	2,3	3,0
MT	6,4	-2,4	2,6	-0,3																								
NL	3,5	1,4	0,6	-0,9	1,5	-3,6	-1,6	-1,9	3,5	0,5	-1,0	-2,1	4,2	2,1	-3,2	-3,0	6,3	0,7	0,8	-1,3	2,9	1,6	-0,4	-0,1	1,6	2,8	2,8	2,3
AT	3,4	0,7	1,2	0,8	-3,0	0,6	-0,5	-1,3	6,2	2,5	1,7	0,2	1,7	-3,5	0,4	5,1	3,2	2,0	2,5	1,8	6,3	0,7	1,6	0,6	1,3	-0,7	-1,3	-0,5
PL	4,0	1,0	1,4	3,8	-7,9	9,2	2,0	2,1	6,5	-0,3	-0,2	6,3	0,3	-7,9	-6,8	-2,9	4,0	3,6	5,9	2,3	4,5	2,7	-0,1	5,8	2,5	0,4	0,2	3,4
PT	3,4	1,7	0,4	-1,2	-4,0	-0,3	5,7	-6,7	2,7	1,9	-1,0	-0,5	4,9	2,8	-3,8	-11,4	4,1	4,0	1,0	0,1	7,1	4,3	0,9	2,0	3,5	2,1	1,5	-1,4
SI	3,9	2,7	3,3	2,5	0,8	-12,1	15,4	-15,3	8,4	5,0	4,7	3,3	0,9	-2,2	0,6	3,4	2,1	3,7	3,4	3,1	1,2	4,7	4,0	4,3	4,8	3,3	2,3	3,0
SK	2,0	3,8	4,6	4,0	1,9	4,9	-1,6	4,4	0,8	1,4	-0,3	9,5	0,2	-0,5	9,3	6,9	2,2	9,7	-3,2	-2,4	2,5	1,9	17,5	8,9	2,8	14,0	16,6	5,5
FI	5,1	1,1	2,3	2,0	10,6	-4,8	3,6	0,6	11,0	0,3	2,1	0,9	-2,6	-2,9	2,5	1,3	5,3	2,8	2,3	3,3	5,3	0,7	2,6	3,6	2,1	3,0	1,8	0,5
SE	4,3	1,0	2,0	1,5	2,8	4,3	2,8	1,2	8,2	-1,6	4,5	1,9	0,7	5,2	-0,4	0,8	3,7	0,5	1,7	2,3	4,9	1,8	-0,3	1,9	1,7	1,4	1,9	1,3
UK	3,9	2,3	1,8	2,2	-0,6	-9,1	11,9	-2,6	1,9	-1,6	-2,5	-0,2	1,3	1,8	3,8	5,2	5,1	2,9	3,6	2,5	5,0	4,6	2,1	4,6	3,2	2,4	2,6	1,3

Izvor: Eurostat DG REGIO.

U projekcijama gospodarskog razvitka hrvatskih regija je kao osnovna odrednica korištena zatečena gospodarska struktura. Za projekciju gospodarskog rasta korištena je regresijska ekonometrijska ocjena u kojoj je kao zavisna varijabla korištena zabilježena stopa rasta pojedinih NUTS II regija za zemlje EU15 i NMS10, a kao nezavisne varijable korišteni su udjeli pojedinih djelatnosti NACE klasifikacije u bruto dodanoj vrijednosti.

Binarna varijabla za NMS10 zemlje dodana je zato što ona omogućuje identifikaciju prosječne brzine konvergencije, odnosno učinka tzv. niske osnovice za NMS zemlje. Ustanovljeno je da je u prošlom razdoblju činjenica da se radi o zemlji kandidatu utjecala na ostvarenje za oko **0,69** postotnih bodova bržeg rasta od prosjeka EU25 (učinak konvergencije)¹⁰, a preostalu razliku do **0,87** postotnih bodova bržeg rasta objašnjavaju ostali strukturni čimbenici. S vremenom valja očekivati da će se brzina konvergencije polako smanjivati. Korištenje strukturnih fondova EU bi u dugoročnom razdoblju moralo zaustaviti proces dalje centralizacije gospodarske aktivnosti u razvijenim regijama i dovesti do uravnoteženijeg rasta regija NMS skupine zemalja.

Zatečena gospodarska struktura na razini ukupnog hrvatskog gospodarstva, uz nastavak procesa približavanja EU, a prema rezultatima ekonometrijske ocjene za europske NUTS II regije, omogućuje *ostvarenje prosječne godišnje stope rasta BDP Hrvatske od oko 4,1% za ukupno projicirano razdoblje (2005.-2015.)*. Unutar pojedinih podrazdoblja valja očekivati da će stope rasta oscilirati ovisno o fazi ciklusa u kojem se nalazi gospodarstvo EU, s kojim je već danas domaće gospodarstvo vrlo intenzivno povezano. Uz očekivani rast EU25 od oko 2,2% godišnje (projekcija WIIW¹¹), *zaostatak za prosjekom EU25 prema projekciji bi se smanjivao prosječno za oko 1,1 postotni bod godišnje u terminima BDP p.c. PPS EU25*.

Budući da je gospodarska struktura hrvatskih regija, kao i u slučaju novih članica, povoljnija u razvijenijim regijama, ***valja očekivati da će se proces povećanja regionalnih razlika u Hrvatskoj u kratkoročnom razdoblju nastaviti. Zaustavljanje toga procesa bit će moguće, uz osmišljavanje izrazito aktivne regionalne politike i uz pomoć europskih strukturnih fondova tek na kraju projiciranog razdoblja.***

¹⁰ Više o modeliranju i testiranju dinamike regionalne konvergencije vidjeti u npr. Arbia, Basile, Piras (2004).

¹¹ WIIW Research Report No. 308.

Projekcije osam različitih varijanti statističke regionalizacije Hrvatske na NUTS II razini i analiza pojedinih izvedenih pokazatelja

U nastavku je prikazano osam varijanti statističke regionalizacije Hrvatske na NUTS II regije s analizom učinaka i ispunjavanjem pojedinih kriterija za EU NUTS II regije. Projekcije su prikazane za razdoblje od 2005. do 2015., s analizom pokazatelja razine razvijenosti u godinama 2005., 2010. i 2015. Polaznu osnovicu razine razvijenosti i gospodarske strukture županija čini preliminarni obračun rezultata bruto domaćeg proizvoda za 2003. godinu po županijama.¹² Svaka varijanta sadrži:

- pokazatelje površine i broja stanovnika po regijama,
- udjele BDP koje bi pojedina regija imala u 2003. i 2015. (struktura BDP, RH = 100),
- indeks razine razvijenosti u odnosu na ostale regije kad je BDP RH=100, 2003.
- BDP p.c. po PPS 2003. bez uključene sive ekonomije¹³, odnosno nakon uključivanja sive ekonomije jer je to obveza Hrvatske prema EU,
- indeks BDP p.c. po PPS 2005. gdje je EU25=100, odnosno EU27=100,¹⁴
- indeks BDP p.c. po PPS 2010. gdje je EU25=100, odnosno EU27=100,
- indeks BDP p.c. po PPS 2015. gdje je EU25=100, odnosno EU27=100.

Osim toga, projekcije sadrže posebno prikazan udio stanovnika Hrvatske u regijama s razinom BDP manjom od 75% od prosjeka EU25, odnosno EU27 (nakon uključivanja Rumunjske i Bugarske), što daje osnovicu za procjenu financijskih učinaka pojedine varijante statističke regionalizacije. Dalje, svaka varijanta projekcije statističke regionalizacije Hrvatske sadrži pokazatelje disperzije, odnosno razlika u razvijenosti pojedinih regija ovisno o odabranom rješenju. Pokazatelji su standardna devijacija i omjer najrazvijenija/najnerazvijenija regija.

Problemi koji bi mogli postojati u pojedinoj varijanti statističke regionalizacije označeni su masnim slovima. Oni ukazuju na situaciju ako pojedina varijanta ne zadovoljava Eurostatov kriterij minimalnog broja stanovnika, odnosno ako BDP p.c. PPS pojedine NUTS II regije prelazi 75% prosjeka EU25. Prvo su promatrane varijante sa tri regije (5 varijanti), zatim sa četiri regije (2 varijante) i sa dvije regije (1 varijanta).

¹² Mikulić, D. i Lovrinčević, Ž. (ur.): "Uvođenje i primjena sustava nacionalnih računa – regionalni BDP za 2003. godinu", istraživanja za 2005. godinu, Zagreb, 2005.

¹³ Ukupni podaci o regionalnom BDP dostupni su za 2001. i 2002. godinu, a regionalna je distribucija BDP za 2003. procijenjena na osnovi raspoloživih pokazatelja.

¹⁴ Sve godine poslije 2003. uključuju sivu ekonomiju u ukupni BDP Republike Hrvatske.

Slika 1.

PRIJEDLOG STATISTIČKE REGIONALIZACIJE HRVATSKE NA TRI NUTS II REGIJE (VARIJANTA 1)



Kontinentalna Hrvatska obuhvaća ove županije: Krapinsko-zagorsku, Sisačko-moslavačku, Karlovačku, Varaždinsku, Koprivničko-križevačku, Bjelovarsko-bilogorsku, Virovitičko-podravsku, Požeško-slavonsku, Brodsko-posavsku, Osječko-baranjsku, Vukovarsko-srijemsku i Međimursku.

Jadransku Hrvatsku čine županije: Primorsko-goranska, Ličko-senjska, Zadarska, Šibensko-kninska, Splitsko-dalmatinska, Istarska i Dubrovačko-neretvanska.

Zagrebačka regija obuhvaća Grad Zagreb i Zagrebačku županiju.

Tablica 5.

PRIJEDLOG STATISTIČKE REGIONALIZACIJE HRVATSKE NA TRI NUTS II REGIJE (VARIJANTA 1)

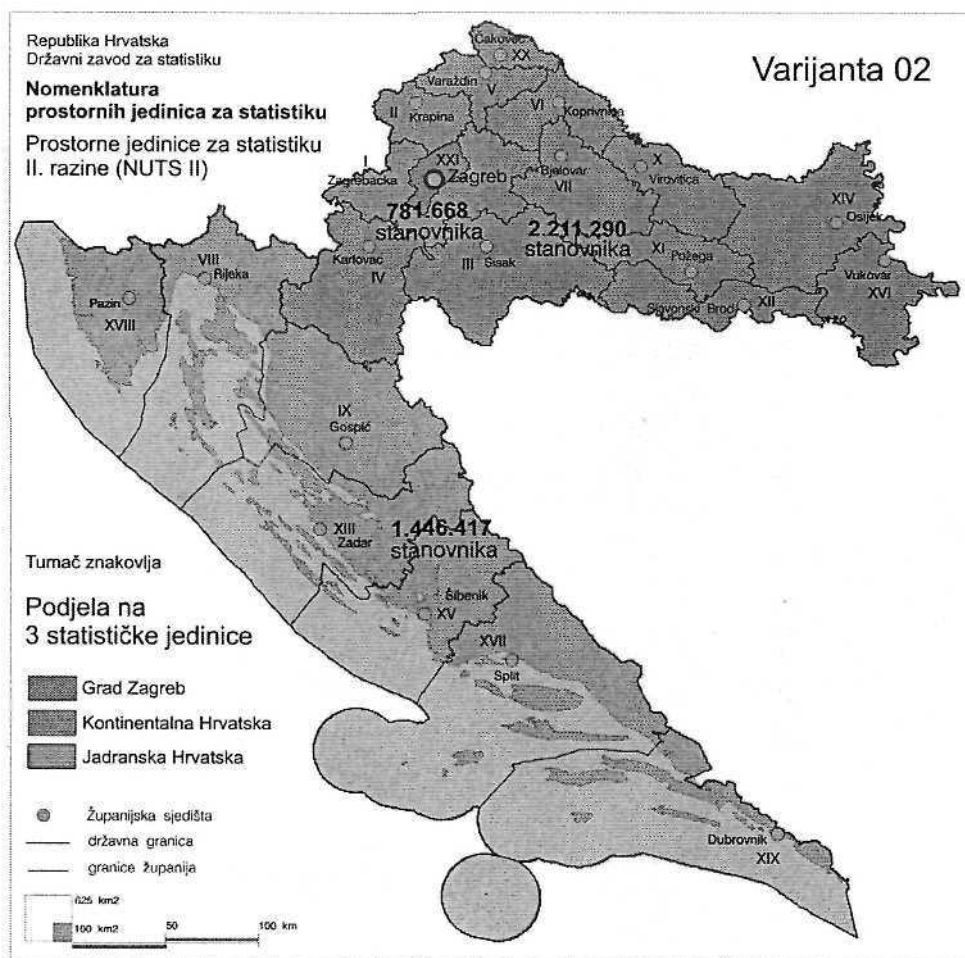
Regija	Površina u km ²	Broj stanovnika, 2004.	BDP p.c., RH=100, 2003.	Struktura BDP		BDP p.c. PPS 2003. - bez uključene sive ekonomije	BDP p.c. PPS 2003. - s uključenom sivom ekonomijom	BDP p.c. PPS 2005.	BDP p.c. PPS 2010.	BDP p.c. PPS 2015.
				2003.	2015.					
Kontinentalna Hrvatska	28.188	1.892.725	76	32,5	31,3	EU25 EU27	EU25 EU27	EU25 EU27	EU25 EU27	EU25 EU27
Jadranska Hrvatska	24.705	1.446.417	95	30,7	31,4	EU25 EU27	EU25 EU27	EU25 EU27	EU25 EU27	EU25 EU27
Zagrebačka regija	3.701	1.100.233	149	36,8	37,2	EU25 EU27	EU25 EU27	EU25 EU27	EU25 EU27	EU25 EU27
Hrvatska	56.594	4.439.375	100	100	100	EU25 EU27	EU25 EU27	EU25 EU27	EU25 EU27	EU25 EU27
Prosječan broj stanovnika NUTS II regije		1.479.877								
Standardna devijacija*	70,2	28,2	38,1	9,4	10,1					
Omjer regija s najvećim udjelom u ukupnom BDP / regija s najmanjim udjelom				1,1	1,2					
Omjer najrazvijenija / najnerazvijenija regija			2,0							
Udio stanovnika u regijama s razinom BDP p.c PPS < 75% EU25										
Procijenjena financijska potpora iz EU strukturalnih fondova 2015. godine										

* prosječno odstupanje u indeksnim bodovima.

6,1 mlrd HRK

Slika 2.

**PRIJEDLOG STATISTIČKE REGIONALIZACIJE HRVATSKE
 NA TRI NUTS II REGIJE (VARIJANTA 2)**



Kontinentalna Hrvatska obuhvaća sljedeće županije: Zagrebačku, Krapinsko-zagorsku, Sisačko-moslavačku, Karlovačku, Varaždinsku, Koprivničko-križevačku, Bjelovarsko-bilogorsku, Virovitičko-podravsku, Požeško-slavonsku, Brodsko-posavsku, Osječko-baranjsku, Vukovarsko-srijemsku i Međimursku.

Jadransku Hrvatsku čine županije: Primorsko-goranska, Ličko-senjska, Zadarska, Šibensko-kninska, Splitsko-dalmatinska, Istarska i Dubrovačko-neretvanska.

Grad Zagreb u ovoj varijanti promatran je kao zasebna statistička jedinica.

Tablica 6.

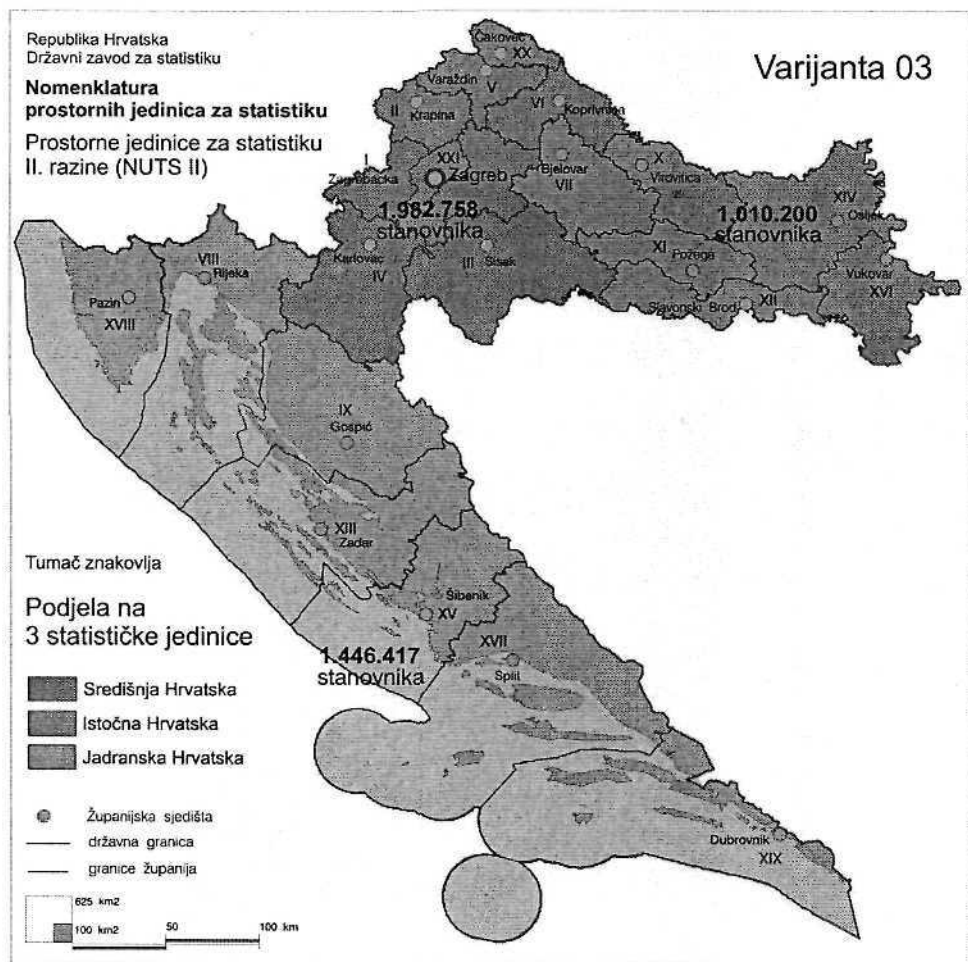
PRIJEDLOG STATISTIČKE REGIONALIZACIJE HRVATSKE NA TRI NUTS II REGIJE (VARIJANTA 2)

Regija	Površina u km ²	Broj stanovnika, 2004.	BDP p.c., RH=100, 2003.	Struktura BDP		BDP p.c. PPS 2003. - s uključenom sivom ekonomijom	BDP p.c. PPS 2005.	BDP p.c. PPS 2010.	BDP p.c. PPS 2015.
				2003.	2015.				
Kontinentalna Hrvatska	31.248	2.211.290	76	37,8	36,6	EU25 40 EU27 41	EU25 40 EU27 41	EU25 43 EU27 44	EU25 46 EU27 48
Jadranska Hrvatska	24.705	1.446.417	95	30,7	31,4	EU25 50 EU27 51	EU25 50 EU27 52	EU25 56 EU27 58	EU25 62 EU27 64
Grad Zagreb	641	781.668	179	31,5	32,0	EU25 84 EU27 86	EU25 95 EU27 98	EU25 105 EU27 109	EU25 116 EU27 120
Hrvatska	56.594	4.439.375	100	100	100	EU25 53 EU27 54	EU25 53 EU27 55	EU25 58 EU27 60	EU25 64 EU27 66
Prosječan broj stanovnika NUTS II regije		1.479.877							
Standardna devijacija*	85,4	49,1	55,1	11,6	8,5				
Omjer regija s najvećim udjelom u ukupnom BDP / regija s najmanjim udjelom				1,2	1,2				
Omjer najrazvijenija / najnerazvijenija regija			2,4						
Udio stanovnika u regijama s razinom BDP p.c. PPS < 75% EU25									
Procijenjena financijska potpora iz EU strukturnih fondova 2015. godine						82,4	82,4	82,4	82,4
									6,7 mrd HRK

* prosječno odstupanje u indeksnim bodovima.

Slika 3.

PRIJEDLOG STATISTIČKE REGIONALIZACIJE HRVATSKE NA TRI NUTS II REGIJE (VARIJANTA 3)



Istočna Hrvatska obuhvaća županije: Bjelovarsko-bilogorsku, Virovitičko-podravsku, Požeško-slavonsku, Brodsko-posavsku, Osječko-baranjsku i Vukovarsko-srijemsku.

Jadranska Hrvatska obuhvaća ove županije: Primorsko-goransku, Ličko-senjsku, Zadarsku, Šibensko-kninsku, Splitsko-dalmatinsku, Istarsku i Dubrovačko-neretvansku.

Središnja Hrvatska obuhvaća županije: Zagrebačku, Krapinsko-zagorsku, Sisačko-moslavačku, Karlovačku, Varaždinsku, Kopriivničko-križevačku, Međimursku i Grad Zagreb.

Tablica 7.

PRIJEDLOG STATISTIČKE REGIONALIZACIJE HRVATSKE NA TRI NUTS II REGIJE (VARIJANTA 3)

Regija	Površina u km ²	Broj stanovnika, 2004.	BDP p.c., RH=100, 2003.	Struktura BDP		BDP p.c. PPS 2003. - bez uključene sive ekonomije	BDP p.c. PPS 2003. - s uključenom sivom ekonomijom	BDP p.c. PPS 2005.	BDP p.c. PPS 2010.	BDP p.c. PPS 2015.
				2003.	2015.					
Istočna Hrvatska	15.126	1.010.200	69	15,8	14,9	EU25 EU27	EU25 EU27	EU25 EU27	EU25 EU27	EU25 EU27
Jadranska Hrvatska	24.705	1.446.417	95	30,7	31,4	EU25 EU27	EU25 EU27	EU25 EU27	EU25 EU27	EU25 EU27
Središnja Hrvatska	16.763	1.982.758	120	53,5	53,7	EU25 EU27	EU25 EU27	EU25 EU27	EU25 EU27	EU25 EU27
Hrvatska	56.594	4.439.375	100	100	100	EU25 EU27	EU25 EU27	EU25 EU27	EU25 EU27	EU25 EU27
Prosječan broj stanovnika NUTS II regije		1.479.877								
Standardna devijacija*	27,2	32,6	25,5	57,0	58,4					
Omjer regija s najvećim udjelom u ukupnom BDP / regija s najmanjim udjelom				3,4	3,6					
Omjer najrazvijenija / najnerazvijenija regija			1,7							
Udio stanovnika u regijama s razinom BDP p.c. PPS < 75% EU25										
Procijenjena financijska potpora iz EU strukturnih fondova 2015. godine								100	100	55,3
										4,5 mlrd HRK

* prosječno odstupanje u indeksnim bodovima.

Slika 4.

PRIJEDLOG STATISTIČKE REGIONALIZACIJE HRVATSKE
 NA TRI NUTS II REGIJE (VARIJANTA 4)



Istočna Hrvatska obuhvaća sljedeće županije: Virovitičko-podravsku, Požeško-slavonsku, Brodsko-posavsku, Osječko-baranjsku i Vukovarsko-srijemsku.

Jadranska Hrvatska obuhvaća ove županije: Primorsko-goransku, Ličko-senjsku, Zadarsku, Šibensko-kninsku, Splitsko-dalmatinsku, Istarsku i Dubrovačko-neretvansku.

Središnja Hrvatska obuhvaća županije: Zagrebačku, Krapinsko-zagorsku, Sisačko-moslavačku, Karlovačku, Varaždinsku, Koprivničko-križevačku, Bjelovarsko-bilogorsku, Međimursku i Grad Zagreb.

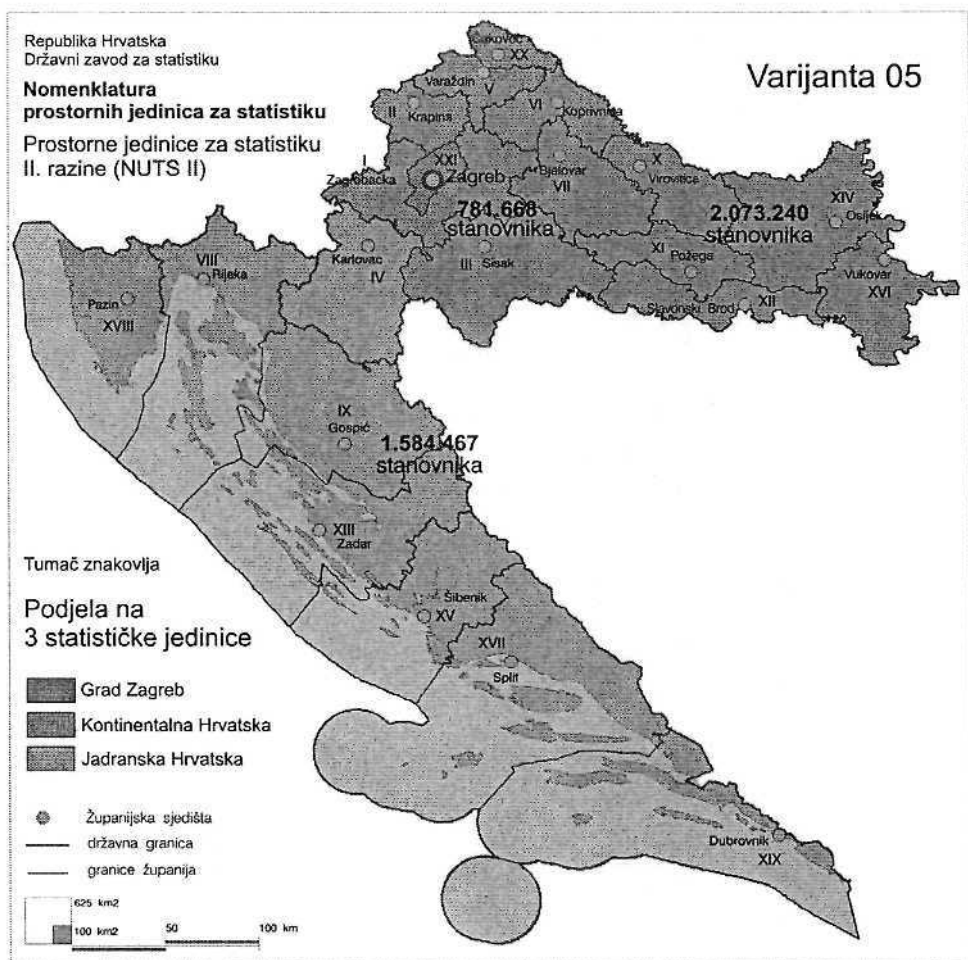
Tablica 8.

PRIJEDLOG STATISTIČKE REGIONALIZACIJE HRVATSKE NA TRI NUTS II REGIJE (VARIJANTA 4)

Regija	Površina u km ²	Broj stanovnika, 2004.	BDP p.c., RH=100, 2003.	Struktura BDP		BDP p.c. PPS 2003. - s uključenom sivom ekonomijom	BDP p.c. PPS 2005.	BDP p.c. PPS 2010.	BDP p.c. PPS 2015.
				2003.	2015.				
Istočna Hrvatska	12.486	880.373	68	13,5	12,7	EU25 36 EU27 37	EU25 36 EU27 37	EU25 38 EU27 39	EU25 41 EU27 42
Jadranska Hrvatska	24.705	1.446.417	95	30,7	31,4	EU25 44 EU27 46	EU25 50 EU27 52	EU25 56 EU27 58	EU25 62 EU27 64
Središnja Hrvatska	19.403	2.112.585	117	55,7	55,9	EU25 55 EU27 57	EU25 62 EU27 64	EU25 68 EU27 70	EU25 75 EU27 77
Hrvatska	56.594	4.439.375	100	100	100	EU25 47 EU27 48	EU25 53 EU27 55	EU25 58 EU27 60	EU25 64 EU27 66
Prosječan broj stanovnika NUTS II regije									
Standardna devijacija*		32,5	41,6	24,7	64,9				
Onijer regija s najvećim udjelom u ukupnom BDP / regija s najmanjim udjelom				4,1	4,4				
Onijer najrazvijenija / najnerazvijenija regija				1,7					
Udio stanovnika u regijama s razinom BDP p.c. PPS< 75% EU25									
Procijenjena financijska potpora iz EU strukturnih fondova 2015. godine				100	100	100	100	100	52,4
4,3 mlrd HRK									

Slika 5.

PRIJEDLOG STATISTIČKE REGIONALIZACIJE HRVATSKE
 NA TRI NUTS II REGIJE (VARIJANTA 5)



Kontinentalna Hrvatska obuhvaća županije: Zagrebačku, Krapinsko-zagorsku, Sisačko-moslavačku, Varaždinsku, Koprivničko-križevačku, Bjelovarsko-bilogorsku, Virovitičko-podravsku, Požeško-slavonsku, Brodsko-posavsku, Osječko-baranjsku, Vukovarsko-srijemsku i Međimursku.

Jadransku Hrvatsku čine županije: Karlovačka, Primorsko-goranska, Ličko-senjska, Zadarska, Šibensko-kninska, Splitsko-dalmatinska, Istarska i Dubrovačko-neretvanska.

Grad Zagreb u ovoj varijanti promatran je kao zasebna statistička jedinica.

Tablica 9.

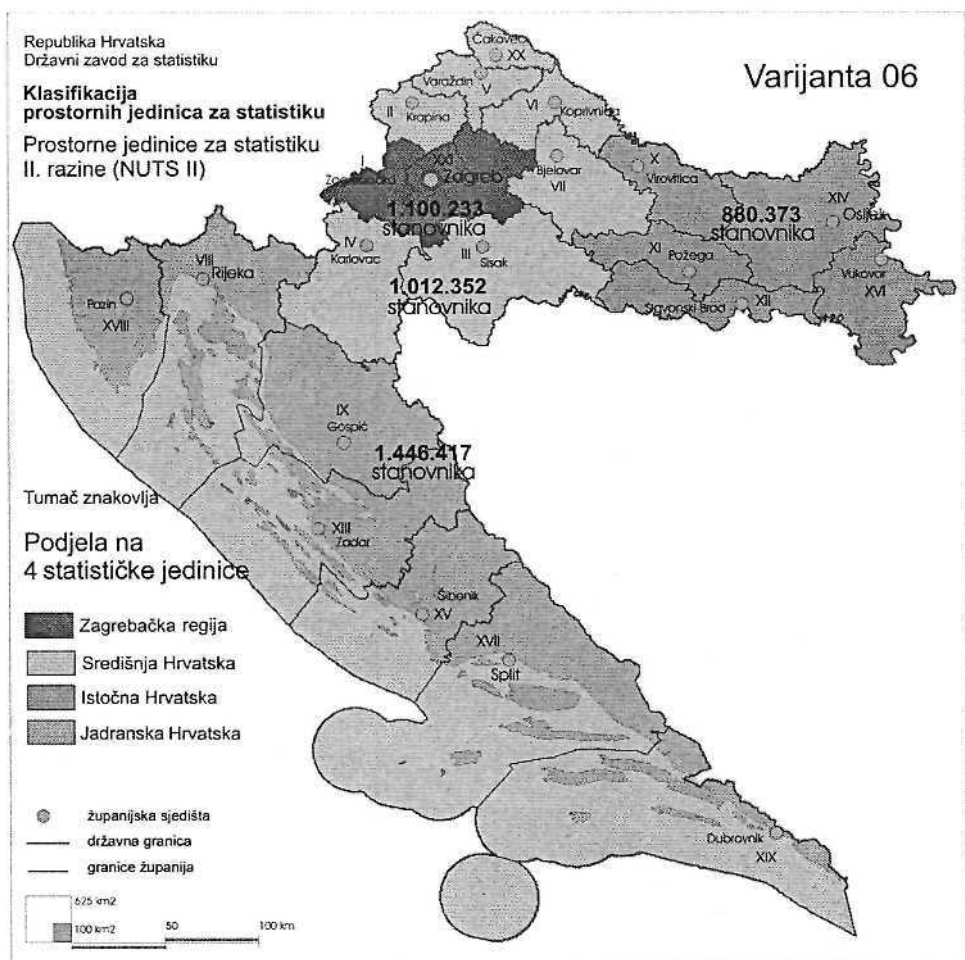
PRIJEDLOG STATISTIČKE REGIONALIZACIJE HRVATSKE NA TRI NUTS II REGIJE (VARIJANTA 5)

Regija	Površina u km ²	Broj stanovnika, 2004.	BDP p.c., RH=100, 2003.	Struktura BDP		BDP p.c. PPS 2003. - s uključenom sivom ekonomijom	BDP p.c. PPS 2005.	BDP p.c. PPS 2010.	BDP p.c. PPS 2015.
				2003.	2015.				
Kontinentalna Hrvatska	27 622	2 073 240	75	35,3	34,1	EU25 36 EU27 37	EU25 40 EU27 41	EU25 43 EU27 44	EU25 46 EU27 48
Jadranska Hrvatska	28 331	1 584 467	93	33,2	33,9	EU25 44 EU27 45	EU25 49 EU27 51	EU25 55 EU27 57	EU25 61 EU27 63
Grad Zagreb	641	781.668	179	31,5	32,0	EU25 84 EU27 86	EU25 94 EU27 97	EU25 105 EU27 109	EU25 116 EU27 120
Hrvatska	56 594	4 439 375	100	100	100	EU25 47 EU27 48	EU25 53 EU27 55	EU25 58 EU27 60	EU25 64 EU27 66
Prosječan broj stanovnika NUTS II regije		1 479 877							
Standardna devijacija*	83,7	44,6	55,5	5,8	3,5				
Omjer regija s najvećim udjelom u ukupnom BDP / regija s najmanjim udjelom				1,1	1,1				
Omjer najrazvijenija / najnerazvijenija regija			2,4						
Udio stanovnika u regijama s razinom BDP p.c. PPS < 75% EU25									
Procijenjena financijska potpora iz EU strukturnih fondova 2015. godine						82,4	82,4	82,4	82,4
									6,7 mlrd HRK

* prosječno odstupanje u indeksnim bodovima.

Slika 6.

PRIJEDLOG STATISTIČKE REGIONALIZACIJE HRVATSKE NA ČETIRI NUTS II REGIJE (VARIJANTA 6 – STARI PRIJEDLOG DZS)



Istočna Hrvatska obuhvaća županije: Virovitičko-podravsku, Požeško-slavonsku, Brodsko-posavsku, Osječko-baranjsku i Vukovarsko-srijemsku.

Jadranska Hrvatska obuhvaća županije: Primorsko-goransku, Ličko-senjsku, Zadar, Šibensko-kninsku, Splitsko-dalmatinsku, Istarsku i Dubrovačko-neretvansku.

Središnja Hrvatska obuhvaća ove županije: Krapinsko-zagorsku, Sisačko-moslavačku, Karlovačku, Varaždinsku, Kopriivničko-križevačku, Bjelovarsko-bilogorsku i Međimursku.

Zagrebačka regija obuhvaća Grad Zagreb i Zagrebačku županiju.

Tablica 10.

PRIJEDLOG STATISTIČKE REGIONALIZACIJE HRVATSKE NA ČETIRI NUTS II REGIJE (VARIJANTA 6
– STARI PRIJEDLOG DZS)

Regija	Površina u km ²	Broj stanovnika, 2004.	BDP p.c., RH=100, 2003.	Struktura BDP		BDP p.c. PPS 2003. - s uključenom sivom ekonomijom	BDP p.c. PPS 2005.	BDP p.c. PPS 2010.	BDP p.c. PPS 2015.
				2003.	2015.				
Istočna Hrvatska	12.486	880.373	68	13,5	12,8	EU25 36 EU27 37	EU25 36 EU27 37	EU25 38 EU27 39	EU25 41 EU27 42
Jadranska Hrvatska	24.705	1.446.417	95	30,7	31,4	EU25 44 EU27 46	EU25 50 EU27 52	EU25 56 EU27 58	EU25 62 EU27 64
Središnja Hrvatska	15.702	1.012.352	83	19,0	18,6	EU25 39 EU27 40	EU25 44 EU27 45	EU25 47 EU27 49	EU25 51 EU27 53
Zagrebačka regija	3.701	1.100.233	149	36,8	37,2	EU25 70 EU27 72	EU25 79 EU27 81	EU25 88 EU27 90	EU25 97 EU27 100
Hrvatska	56.594	4.439.375	100	100	100	EU25 47 EU27 48	EU25 53 EU27 55	EU25 58 EU27 60	EU25 64 EU27 66
Prosječan broj stanovnika NUTS II regije		1.109.908							
Standardna devijacija*	61,3	20,6	35,4	42,6	45,1				
Onijer regija s najvećim udjelom u ukupnom BDP / regija s najmanjim udjelom				2,7	2,9				
Onijer najrazvijenija / najnerazvijenija regija			2,2						
Udio stanovnika u regijama s razinom BDP p.c. PPS < 75% EU25				100					
Procijenjena financijska potpora iz EU strukturnih fondova 2015. godine							75,2	75,2	75,2
									6,1 mlrd HRK

* prosječno odstupanje u indeksnim bodovima.

Slika 7.

PRIJEDLOG STATISTIČKE REGIONALIZACIJE HRVATSKE NA ČETIRI NUTS II REGIJE (VARIJANTA 7)



Istočna Hrvatska obuhvaća županije: Bjelovarsko-bilogorsku, Virovitičko-podravsku, Požeško-slavonsku, Brodsko-posavsku, Osječko-baranjsku i Vukovarsko-srijemsku.

Jadranska Hrvatska obuhvaća županije: Primorsko-goransku, Ličko-senjsku, Zadarsku, Šibensko-kninsku, Splitsko-dalmatinsku, Istarsku i Dubrovačko-neretvansku.

Središnja Hrvatska obuhvaća županije: Zagrebačku, Krapinsko-zagorsku, Sisačko-moslavačku, Karlovačku, Varaždinsku, Koprivničko-križevačku i Međimursku.

Grad Zagreb u ovoj varijanti promatran je kao zasebna statistička jedinica.

Tablica 11.

PRIJEDLOG STATISTIČKE REGIONALIZACIJE HRVATSKE NA ČETIRI NUTS II REGIJE (VARIJANTA 7)

Regija	Površina u km ²	Broj stanovnika, 2004.	BDP p.c., RH=100, 2003.	Struktura BDP		BDP p.c. PPS 2003. - bez uključene sive ekonomije	BDP p.c. PPS 2003. - s uključenom sivom ekonomijom	BDP p.c. PPS 2005.	BDP p.c. PPS 2010.	BDP p.c. PPS 2015.
				2003.	2015.					
Istočna Hrvatska	15.126	1.010.200	69	15,8	14,9	EU25 EU27	EU25 EU27	EU25 EU27	EU25 EU27	EU25 EU27
Jadranska Hrvatska	24.705	1.446.417	95	30,7	31,4	EU25 EU27	EU25 EU27	EU25 EU27	EU25 EU27	EU25 EU27
Središnja Hrvatska	16.122	1.201.090	81	22,0	21,7	EU25 EU27	EU25 EU27	EU25 EU27	EU25 EU27	EU25 EU27
Grad Zagreb	641	781.668	179	31,5	32,0	EU25 EU27	EU25 EU27	EU25 EU27	EU25 EU27	EU25 EU27
Hrvatska	56.594	4.439.375	100	100	100	EU25 EU27	EU25 EU27	EU25 EU27	EU25 EU27	EU25 EU27
Prosječan broj stanovnika NUTS II regije										
Standardna devijacija*		70,5	24,9	49,9	30,0	32,9				
Omjer regija s najvećim udjelom u ukupnom BDP / regija s najmanjim udjelom										
Omjer najrazvijenija / najnerazvijenija regija										
Udio stanovnika u regijama s razinom BDP p.c. PPS< 75% EU25										
Procijenjena financijska potpora iz EU strukturnih fondova 2015. godine										
				82,4		82,4	82,4	82,4	82,4	6,7 mlrd HRK

* prosječno odstupanje u indeksnim bodovima.

Slika 8.

PRIJEDLOG STATISTIČKE REGIONALIZACIJE HRVATSKE NA DVIJE NUTS II REGIJE (VARIJANTA 8)



Panonska Hrvatska obuhvaća županije: Zagrebačku, Krapinsko-zagorsku, Sisačko-moslavačku, Varaždinsku, Koprivničko-križevačku, Bjelovarsko-bilogorsku, Virovitičko-podravsku, Požeško-slavonsku, Brodsko-posavsku, Osječko-baranjsku, Vukovarsko-srijemsku, Međimursku i Grad Zagreb

Jadranska Hrvatska obuhvaća županije: Karlovačku, Primorsko-goransku, Ličko-senjsku, Zadarsku, Šibensko-kninsku, Splitsko-dalmatinsku, Istarsku i Dubrovačko-neretvansku.

Tablica 12.

PRIJEDLOG STATISTIČKE REGIONALIZACIJE HRVATSKE NA TRI NUTS II REGIJE (VARIJANTA 8)

Regija	Površina u km ²	Broj stanovnika, 2004.	BDP p.c., RH=100, 2003.	Struktura BDP		BDP p.c. PPS 2003. - s uključenom svom ekonomijom	BDP p.c. PPS 2005.	BDP p.c. PPS 2010.	BDP p.c. PPS 2015.
				2003.	2015.				
Panonska Hrvatska	28.263	2.854.908	104	66,8	66,1	EU25 49 EU27 50	EU25 55 EU27 56	EU25 60 EU27 62	EU25 65 EU27 67
Jadranska Hrvatska	28.331	1.584.467	93	33,2	33,9	EU25 44 EU27 45	EU25 49 EU27 51	EU25 55 EU27 57	EU25 61 EU27 63
Hrvatska	56.594	4.439.375	100	100	100	EU25 47 EU27 48	EU25 53 EU27 54	EU25 58 EU27 60	EU25 64 EU27 66
Prosječan broj stanovnika NUTS II regije 2.218.816									
Standardna devijacija* 0,2 41,3 7,4 47,5 45,6									
Omjer regija s najvećim udjelom u ukupnom BDP / regija s najmanjim udjelom 2,0 2,0									
Omjer najrazvijenija / najnerazvijenija regija 1,1									
Udio stanovnika u regijama s razinom BDP p.c. PPS< 75% EU25 100 100 100 100 100									
Procijenjena financijska potpora iz EU strukturalnih fondova 2015. godine 8,2 mlrd HRK									

* prosječno odstupanje u indeksnim bodovima.

Analiza zatečene gospodarske homogenosti pojedinih varijanti statističke regionalizacije Hrvatske – cluster analiza

U prethodnom dijelu prikazane su projekcije i pokazatelji pojedinih varijanti statističke regionalizacije Hrvatske na NUTS II razini. Primarna je namjena bila vidjeti koju će razinu razvijenosti ostvariti pojedine regije u odnosu na BDP p.c. EU25=100, odnosno razinu ravnomjernosti regionalne raspodjele gospodarske aktivnosti u Hrvatskoj. Ovo poglavlje uzima kao polaznu osnovicu naprijed prikazanih osam varijanti regionalizacije i pokušava dati odgovor na pitanje: koliko je homogena pojedina varijanta statističke regionalizacije Hrvatske? Homogenost obuhvaća gospodarski, demografski i socijalni aspekt. Viša razina regionalne homogenosti pojedine varijante regionalizacije Hrvatske mora poslužiti kao dobra osnovica za vođenje **konzistentne regionalne politike** u dugom razdoblju. U sljedećem poglavlju će potom biti sagledana oba kriterija zajedno (financijski i kriterij homogenosti), pri pokušaju procjene optimalne varijante statističke regionalizacije Hrvatske na NUTS II regije.

Uvod

U ovom dijelu analizirana je homogenost hrvatskih županija sa ciljem njihovog grupiranja u prostorne jedinice za statistiku II. razine. Homogenost hrvatskih županija analizirana je na osnovi sljedeće 22 varijable: udio sive ekonomije, stopa nezaposlenosti, udio zaposlenih u primarnom sektoru, udio zaposlenih u sekundarnom sektoru, udio zaposlenih u tercijarnom sektoru, udio zaposlenih u turizmu, udio zaposlenih u tercijarnom sektoru bez turizma, udio zaposlenih u tercijarnom sektoru bez javne uprave, udio zaposlenih u tercijarnom sektoru bez turizma i javne uprave, BDP per capita, BDP po zaposlenom, udio stanovništva s primarnim obrazovanjem, udio stanovništva sa sekundarnim obrazovanjem, udio stanovništva s tercijarnim obrazovanjem, neto plaće, udio stanovništva mlađeg od 15 godina, udio radnog kontingenta (muškarci u dobi 15-64, a žene 15-59), udio starijeg stanovništva (muškarci stariji od 65, a žene od 60 godina), porezni prihodi u BDP, porezni prihodi po stanovniku, broj stanovnika na km ceste, gustoća cesta.

Podaci se odnose na 2002. godinu, a analizirani su u obliku indeksa na osnovi prosjeka Republike Hrvatske (Hrvatska=100).

Homogenost hrvatskih županija procjenjivana je metodom cluster analize, pri čemu je kao metoda grupiranja upotrijebljena nodalna metoda, i to k-means pristup. Ta podvrsta cluster analize je odabrana zbog svoje fleksibilnosti u zadavanju broja željenih grupa. Naime, za razliku od nekih drugih pristupa cluster analizi,

k-means pristup podrazumijeva zadavanje broja maksimalno različitih grupa (k) koji se želi postići analizom, i to prije same analize. Procedura k-means analize nakon toga formira zadani broj grupa koje su maksimalno različite među sobom, a elementi su pojedinih grupa minimalno različiti unutar grupe. Dakle, pojedini se elementi pridružuju pojedinim grupama da bi se postigla heterogenost među grupama (interregionalna heterogenost) i homogenost unutar svake pojedine grupe (intraregionalna homogenost).

Procedura k-means može se opisati kao svojevrsno obrnuto provođenje ANOVA analize. Naime, procedurom k-means analizirani se objekti (u ovom slučaju županije) uvrstavaju i isključuju iz clustera sve dok se ne dobije rješenje s najboljom signifikantnošću rezultata ANOVA analize. Pri tom se veličinom F vrijednosti koristi kao pokazateljem kako pojedina analizirana varijabla diskriminira među clusterima.

Kod primijenjene k-means cluster analize statistički generirani centar clustera dobiva se procedurom u kojoj se objekti prvo razvrstavaju prema njihovim međusobnim udaljenostima. Nakon toga se odabire k centara clustera (k je unaprijed zadani broj clustera). Pokušava se sve objekte svrstati u k clustera i to pridruživanjem odabranim centrima clustera prema njihovoj udaljenosti od početnog centra clustera. Opisana se procedura ponavlja sve dok se ne odaberu centri clustera koji omogućuju grupiranje svih objekata u k clustera, što rezultira najboljom signifikantnošću rezultata ANOVA analize.

Kod k-means procedure udaljenosti među objektima i između objekata i centara clustera izražavaju se neskalaranim kvadriranim Euklidskim udaljenostima. Na primjer, udaljenost $D(i,k)$ objekta i od centra clustera k za M analiziranih varijabli X_j se računa prema formuli:

$$D(i,k) = \sqrt{\frac{1}{M} \sum_{j=1}^M (X_{ij} - \bar{X}_j^{(k)})^2}$$

gdje je $\bar{X}_j^{(k)}$ srednja vrijednost varijable j za cluster k .

Iz prikazane se formule vidi da vrijednosti varijabli nisu reskalirane ni na koji način, pa se udaljenost među pojedinim objektima i između objekata i centara clustera izražavaju u mjernim jedinicama analiziranih varijabli. U prikazanoj su analizi sve varijable izražene u indeksima u odnosu na prosjek Hrvatske.

Karakteristike te metode odgovaraju cilju koji se želi postići ovom analizom, tj. utvrditi koji prijedlog statističke regionalizacije Republike Hrvatske na NUTS II regije ima najviše uporišta u homogenosti pojedinih županija. Provedene su analize za grupiranje županija u dvije, tri i četiri statističke jedinice. U nastavku su prikazani rezultati analize uz prijedloge najboljih rješenja na osnovi podataka upotrijebljenih u analizi.

Rezultati cluster analize

Grupiranje županija u dvije statističke jedinice

Analiza grupiranja županija u dvije međusobno heterogene grupe, uz maksimalnu homogenost unutar pojedine grupe, rezultirala je sljedećim rješenjem:

Cluster 1: Primorsko-goranska županija (15,02), Splitsko-dalmatinska županija (17,68), Dubrovačko-neretvanska županija (27,76), Zadarska županija (29,02), Istarska županija (30,22), Šibensko-kninska županija (33,44), Grad Zagreb (117,51).

Cluster 2: Požeško-slavonska županija (10,24), Brodsko-posavska županija (14,50), Virovitičko-podravska županija (16,50), Zagrebačka županija (18,27), Krapinsko-zagorska županija (18,53), Osječko-baranjska županija (19,38), Vukovarsko-srijemska županija (20,35), Sisačko-moslavačka županija (20,79), Karlovačka županija (20,90), Međimurska županija (21,66), Koprivničko-križevačka županija (22,37), Varaždinska županija (28,40), Bjelovarsko-bilogorska županija (31,73), Ličko-senjska županija (40,81).

Županije su poredane prema kriteriju udaljenosti od statistički generiranog centra clustera. Udaljenosti pojedinih županija od statistički generiranog centra clustera prikazana je u zagradaama uz svaku županiju.

U Tablici 13 prikazani su rezultati ANOVA analize kojom se ispituje statistička značajnost razlika među pojedinim clusterima.

Tablica 13.

ANOVA – DVA CLUSTERA

Varijabla	F	signif.
Udio sive ekonomije	11,58743	0,002977
Stopa nezaposlenosti	0,81131	0,379009
Udio zaposlenih u primarnom sektoru	35,04245	0,000011
Udio zaposlenih u sekundarnom sektoru	7,14580	0,015034
Udio zaposlenih u tercijarnom sektoru	51,69595	0,000001
Udio zaposlenih u turizmu	18,78135	0,000358
Udio zaposlenih u tercijarnom sektoru bez turizma	26,63401	0,000056
Udio zaposlenih u tercijarnom sektoru bez javne uprave	64,32090	0,000000
Udio zaposlenih u tercijarnom sektoru bez turizma i javne uprave	49,21083	0,000001
BDP po stanovniku	4,31864	0,051492
BDP po zaposlenom	1,69428	0,208599
Udio stanovništva s primarnim obrazovanjem	48,02032	0,000001
Udio stanovništva sa sekundarnim obrazovanjem	34,58931	0,000012
Udio stanovništva s tercijarnim obrazovanjem	33,89721	0,000013
Neto plaće	16,41726	0,000681
Udio stanovništva mlađeg od 15 godina	1,16717	0,293507
Udio radnog kontingenta	2,06020	0,167449
Udio starijeg stanovništva (muškarci stariji od 65, a žene od 60 godina)	0,22614	0,639822
Porezni prihodi u BDP	21,93853	0,000162
Porezni prihodi po stanovniku	11,77894	0,002794
Broj stanovnika na km ceste	1,92754	0,181092
Gustoća cesta	0,45319	0,508929

Grupiranje županija u dva homogena clustera ne pokazuje zadovoljavajuće rezultate. Grad Zagreb svrstan je u cluster 1 kojeg čine uglavnom županije jadranskog dijela Hrvatske što pokazuje značajnu heterogenost između Grada Zagreba i njegovog okruženja. No, prevelika udaljenost od statistički generiranog centra (117,51) čini Grad Zagreb neodgovarajućim elementom clustera 1, pa se isto tako ne može povezati ni sa clusterom 2, Kontinentalnom Hrvatskom. **Navedeni rezultat upućuje na činjenicu da bi se Grad Zagreb vjerojatno mogao izdvojiti u zaseban cluster, što će biti ispitano u sljedećem dijelu analize, u kojem će biti analizirano grupiranje županija u tri clustera.**

Iz rezultata analize može se također zapaziti da Ličko-senjska županija u rješenju sa dva clustera posjeduje veći stupanj gospodarske homogenosti s kontinentalnim županijama, pa je i svrstana u grupu 2 s ostalim kontinentalnim županijama. Isto vrijedi i za **Karlovačku županiju koja pokazuje još veći stupanj gospodarske homogenosti s kontinentalnim županijama. Kod kriterija homogenosti, može se zaključiti da varijanta podjele Republike Hrvatske na dvije statističke jedinice (Varijanta 8, Slika 8) ne ispunjava zahtjev elementarne homogenosti regionalne strukture.**

Grupiranje županija u tri statističke jedinice

Analiza grupiranja županija u tri statističke regije, međusobno heterogene, uz maksimalnu homogenost unutar pojedine grupe, rezultirala je sljedećim rješenjem:

Cluster 1: Grad Zagreb (0,00)

Cluster 2: Zadarska županija (13,08), Dubrovačko-neretvanska županija (15,55), Šibensko-kninska (16,76), Splitsko-dalmatinska (17,43), Primorsko-goranska županija (20,76), Istarska županija (25,31), Ličko-senjska županija (33,64).

Cluster 3: Požeško-slavonska županija (9,80), Brodsko-posavska županija (14,02), Virovitičko-podravska županija (16,24), Krapinsko-zagorska županija (17,39), Zagrebačka županija (18,62), Osječko-baranjska županija (19,66), Međimurska županija (19,68), Vukovarsko-srijemska županija (20,62), Sisačkomoslavačka županija (21,39), Koprivničko-križevačka županija (21,51), Karlovačka županija (22,43), Varaždinska županija (27,70), Bjelovarsko-bilogorska županija (31,36).

U Tablici 14 prikazani su rezultati ANOVA analize kojom se ispituje statistička značajnost razlika među pojedinim clusterima kod rješenja sa tri clustera.

Tablica 14.

ANOVA – TRI CLUSTERA

Varijable	F	signif.
Udio sive ekonomije	2,5748	0,103890
Stopa nezaposlenosti	1,4317	0,264850
Udio zaposlenih u primarnom sektoru	12,2346	0,000441
Udio zaposlenih u sekundarnom sektoru	7,5019	0,004270
Udio zaposlenih u tercijarnom sektoru	34,1237	0,000001
Udio zaposlenih u turizmu	58,0671	0,000000
Udio zaposlenih u tercijarnom sektoru bez turizma	14,0248	0,000213
Udio zaposlenih u tercijarnom sektoru bez javne uprave	32,9449	0,000001
Udio zaposlenih u tercijarnom sektoru bez turizma i javne uprave	19,1761	0,000035
BDP po stanovniku	14,7904	0,000159
BDP po zaposlenom	4,7841	0,021566
Udio stanovništva s primarnim obrazovanjem	17,3511	0,000063
Udio stanovništva sa sekundarnim obrazovanjem	9,0707	0,001885
Udio stanovništva s tercijarnim obrazovanjem	39,6421	0,000000
Neto plaće	28,1862	0,000003
Udio stanovništva mlađeg od 15 godina	1,4123	0,269311
Udio radnog kontingenta	1,0748	0,362290
Udio starijeg stanovništva (muškarci stariji od 65, a žene od 60 godina)	0,7389	0,491580
Porezni prihodi u BDP	17,4147	0,000062
Porezni prihodi po stanovniku	49,4579	0,000000
Broj stanovnika na km ceste	150,9350	0,000000
Gustoća cesta	9,4360	0,001575

U usporedbi s rješenjem sa dva clustera, rješenje s tri clustera pokazuje veći stupanj heterogenosti među clusterima (veći broj varijabli statistički se značajno razlikuje među segmentima), jednako kao i veći stupanj homogenosti unutar clustera (nijedna županija ne pokazuje ekstremnu udaljenost od statistički generiranog centra clustera). Kao što je i očekivano, nakon analize rezultata grupiranja županija u dva clustera, Grad Zagreb izdvojio se kao zaseban cluster. Ostale su se županije podijelile na dva clustera koji se ujedno mogu nazvati Kontinentalna Hrvatska i Jadranska Hrvatska.

Naredna se varijanta (Varijanta 5, Slika 5) razlikuje od varijante 2, po tome što Karlovačku županiju svrstava u Jadransku Hrvatsku. Provedena cluster analiza pokazuje da se prema kriteriju gospodarske homogenosti Karlovačka županija lakše svrstava uz ostale županije Kontinentalne Hrvatske nego Jadranske Hrvatske.

Ostale varijante podjele Republike Hrvatske na tri statističke jedinice ne iskazuju izraženu homogenost (varijante 1, 3 i 4) i smanjuju mogućnost vođenja konzistentne regionalne politike. Kod ostalih varijanti sa tri statističke regije, sljedeća varijanta podjele Republike Hrvatske na tri statističke jedinice svrstava zajedno Grad Zagreb i Zagrebačku županiju (Varijanta 1, Slika 1). No, provedena cluster analiza ukazuje na činjenicu da Zagrebačka županija pokazuje značajan stupanj gospodarske homogenosti s ostalim županijama Kontinentalne Hrvatske, a Grad Zagreb pokazuje visoki stupanj heterogenosti u odnosu na sve ostale županije, pa tako i u odnosu na Zagrebačku županiju. Iz navedenoga proizlazi da ta varijanta smanjuje mogućnost da konzistentnu regionalnu politiku vodi središnja država.

Ostale dvije varijante podjele Republike Hrvatske na tri statističke jedinice dijele Republiku Hrvatsku na Središnju, Istočnu i Jadransku Hrvatsku (Varijanta 3, Slika 3 i Varijanta 4, Slika 4). *Obje varijante nemaju uporište u analizi gospodarske homogenosti. Varijanta 3 prikazana na Slici 3 dijeli županije Kontinentalne Hrvatske u dvije zasebne skupine, a rezultati analize gospodarske homogenosti nedvojbeno pokazuju da županije Kontinentalne Hrvatske pokazuju visoki stupanj međusobne gospodarske homogenosti.* Ni jedna županija Kontinentalne Hrvatske nema veliku udaljenost od statistički generiranog centra clustera. Dodatan problem sa stajališta gospodarske homogenosti jest uključivanje Grada Zagreba u Središnju Hrvatsku. Naime, Grad Zagreb ne pokazuje gospodarsku homogenost s ostalim županijama Kontinentalne Hrvatske, nego pokazuje izrazitu heterogenost u odnosu na sve ostale hrvatske županije.

Da bi se dodatno ispitala opravdanost (sa stajališta gospodarske homogenosti) podjele Kontinentalne Hrvatske na dvije statističke jedinice, provedena je cluster analiza samo za županije Kontinentalne Hrvatske. Analiza grupiranja županija Kontinentalne Hrvatske u dvije međusobno heterogene grupe, uz maksimalnu homogenost unutar pojedine grupe, rezultirala je slijedećim rješenjem:

Cluster 1: Grad Zagreb (0,00)

Cluster 2: Požeško-slavonska županija (9,80), Brodsko-posavska županija (14,02), Virovitičko-podravska županija (16,24), Krapinsko-zagorska županija (17,39), Zagrebačka županija (18,62), Osječko-baranjska županija (19,66), Međimurska županija (19,68), Vukovarsko-srijemska županija (20,62), Sisačko-moslavačka županija (21,39), Koprivničko-križevačka županija (21,51), Karlovačka županija (22,43), Varaždinska županija (27,70), Bjelovarsko-bilogorska županija (31,36).

I iz tako obavljene analize proizlazi zaključak da županije Kontinentalne Hrvatske posjeduju visoki stupanj međusobne gospodarske homogenosti i da sa stajališta gospodarske homogenosti ne postoji analitička podloga za dijeljenje županija Kontinentalne Hrvatske u dvije zasebne jedinice. Također je dodatno pokazano da Grad Zagreb ne posjeduje gospodarsku homogenost s ostalim županijama Kontinentalne Hrvatske i da pokazuje izrazitu gospodarsku heterogenost u odnosu na ostale županije Kontinentalne Hrvatske općenito, jednako kao i u odnosu na one županije koje su u varijantama 3 i 4 prikazanim na Slikama 3 i 4 svrstane u Središnju Hrvatsku sa Gradom Zagrebom.

Grupiranje županija u četiri statističke jedinice

Analiza grupiranja županija u četiri međusobno heterogene grupe, uz maksimalnu homogenost unutar pojedine grupe, rezultirala je ovakvim rješenjem:

Cluster 1: Zadarska županija (13,08), Dubrovačko-neretvanska županija (15,55), Šibensko-kninska županija (16,76), Splitsko-dalmatinska županija (17,43), Primorsko-goranska županija (20,76), Istarska županija (25,31), Ličko-senjska županija (33,64).

Cluster 2: Osječko-baranjska županija (12,41), Sisačko-moslavačka županija (12,64), Zagrebačka županija (12,67), Karlovačka županija (12,82), Brodsko-posavska županija (15,92), Varaždinska županija (20,91).

Cluster 3: Virovitičko-podravska županija (10,79), Krapinsko-zagorska županija (12,79), Koprivničko-križevačka županija (12,93), Požeško-slavonska županija (14,57), Međimurska županija (17,19), Bjelovarsko-bilogorska županija (19,63), Vukovarsko-srijemska županija (21,00).

Cluster 4: Grad Zagreb (0,00).

U Tablici 15 prikazani su rezultati ANOVA analize kojom se ispituje statistička značajnost razlika među pojedinim clusterima kod grupiranja u četiri cluster.

Rezultati analize dodatno potvrđuju zaključak o gospodarskoj homogenosti županija Jadranske Hrvatske (cluster 1) i o heterogenosti Grada Zagreba u odnosu na sve ostale hrvatske županije. Županije Kontinentalne Hrvatske podijeljene su u dva međusobno heterogena clustera, ali generirani clusteri ne odgovaraju ni jednom prijedlogu podjele Republike Hrvatske na četiri statističke jedinice (Varijanta 6, Slika 6 i Varijanta 7, Slika 7). Na primjer, gospodarski homogenima pokazale su se županije Istočne Hrvatske - Osječko-baranjska i Brodsko-posavska - sa županijama Središnje Hrvatske - Sisačko-moslavačkom, Zagrebačkom, Karlovačkom, i Varaždinskom. Isto su se tako županije Istočne Hrvatske - Virovitičko-podravska, Požeško-slavonska i Vukovarsko-srijemska – pokazale gospodarski homogenima sa županijama Središnje Hrvatske - Krapinsko-zagorskom, Koprivničko-križevačkom i Međimurskom. Bjelovarsko-bilogorska županija, koja je u jednom prijedlogu (Varijanta 7, Slika 7) svrstana u Istočnu Hrvatsku, a u drugom prijedlogu (Varijanta 6, Slika 6) u Središnju Hrvatsku, gospodarski je homogena sa trima županijama Istočne Hrvatske i sa trima županijama Središnje Hrvatske.

Tablica 15.

ANOVA – ČETIRI CLUSTERA

Varijabla	F	signif.
Udio sive ekonomije	2,56330	0,088860
Stopa nezaposlenosti	1,09399	0,378604
Udio zaposlenih u primarnom sektoru	28,43344	0,000001
Udio zaposlenih u sekundarnom sektoru	5,34563	0,008883
Udio zaposlenih u tercijarnom sektoru	40,47160	0,000000
Udio zaposlenih u turizmu	38,20988	0,000000
Udio zaposlenih u tercijarnom sektoru bez turizma	9,77928	0,000559
Udio zaposlenih u tercijarnom sektoru bez javne uprave	35,04118	0,000000
Udio zaposlenih u tercijarnom sektoru bez turizma i javne uprave	21,18703	0,000006
BDP po stanovniku	9,38654	0,000691
BDP po zaposlenom	4,78681	0,013507
Udio stanovništva s primarnim obrazovanjem	16,93815	0,000024
Udio stanovništva sa sekundarnim obrazovanjem	10,35479	0,000413
Udio stanovništva s tercijarnim obrazovanjem	30,02361	0,000001
Neto plaće	21,16528	0,000006
Udio stanovništva mlađeg od 15 godina	1,38760	0,280594
Udio radnog kontingenta	0,72830	0,549109
Udio starijeg stanovništva (muškarci stariji od 65, a žene od 60 godina)	0,51921	0,674717
Porezni prihodi u BDP	17,67463	0,000018
Porezni prihodi po stanovniku	35,48479	0,000000
Broj stanovnika na km ceste	95,57523	0,000000
Gustoća cesta	5,99535	0,005586

Na osnovi rezultata analize gospodarske homogenosti županija može se zaključiti da varijanta 7 prikazana na Slici 7 predstavlja bolje rješenje od varijante 6 prikazane na Slici 6. Varijanta na Slici 7 u skladu je s gospodarskom homogenošću županija Jadranske Hrvatske, te heterogenošću Grada Zagreba u odnosu na ostale hrvatske županije. Iako županije Istočne i Središnje Hrvatske prikazane na Slici 7 nisu sasvim gospodarski homogene, ipak cluster 2 sadrži većinu županija Središnje Hrvatske (od sedam županija Središnje Hrvatske, njih se četiri nalaze u clusteru 2), a cluster 3 sadrži većinu županija Istočne Hrvatske (od šest županija Istočne Hrvatske, njih se četiri nalaze u clusteru 3, pri čemu se i Bjelovarsko-bilogorska županija promatra kao županija Istočne Hrvatske). *Sa stajališta gospodarske homogenosti, Bjelovarsko-bilogorska županija u većoj mjeri pripada Istočnoj Hrvatskoj. Naime, navedena je županija gospodarski heterogena s većinom županija Središnje Hrvatske (sa četiri od sedam županija središnje Hrvatske), a gospodarski je homogena s većinom županija Istočne Hrvatske (sa tri od pet županija Istočne Hrvatske).*

Zaključno o homogenosti hrvatskih regija na NUTS II razini

Varijanta 2 podjele Republike Hrvatske na statističke jedinice prikazana na Slici 2, najbolje odgovara rezultatima analize gospodarske homogenosti županija. Naime, cluster analiza pokazala je da upravo tako grupirane županije rezultiraju maksimalnom homogenošću unutar pojedinih clustera i maksimalnom heterogenošću među pojedinim clusterima. Visoka razina homogenosti, iako nešto manje izražena, dobiva se i kod varijante 5. Razlika između varijanti 2 i 5 sastoji se jedino u činjenici da je u varijanti 5 Karlovačka županija sastavnica Jadranske Hrvatske, a u varijanti 2 Kontinentalne Hrvatske.

Osim gore navedene varijante, i **varijanta 7 prikazana na Slici 7 u nešto manjoj mjeri odgovara rezultatima analize gospodarske homogenosti županija. Jadranska Hrvatska i Grad Zagreb pokazali su se i prilikom ove cluster analize kao zasebni clusteri,** a među županijama Istočne i Središnje Hrvatske nije sasvim zadovoljen uvjet gospodarske homogenosti. **Ostale varijante ne ispunjavaju zahtjev homogenosti (varijante 1, 3, 4, 6 i 8).**

Zaključna analiza prednosti i nedostataka pojedinih varijanti statističke regionalizacije Hrvatske na NUTS II razini s obrazloženjem

U ovom su poglavlju prikazane prednosti i nedostaci svake od osam (8) varijanti statističke regionalizacije Hrvatske na NUTS II razini. Osnovni kriteriji

za određivanje prednosti, odnosno nedostataka pojedinih varijanti prikazani su u Tablici 16. To su:

- minimalni i maksimalni broj stanovnika kao kriterij Eurostata,
- očekivana vrijednost raspoloživih sredstava iz EU strukturnih fondova 2015. godine,
- gospodarska homogenost.

Minimalan, odnosno maksimalan broj stanovnika NUTS II regija prije je kriterij određivanja statističkih regija nego pokazatelj optimalnosti izbora pojedine varijante statističke regionalizacije. On se ovdje navodi kao jedna od osnovnih preporuka za određivanje NUTS II regija, što ne znači da ne postoje odstupanja od tog kriterija. No, svako odstupanje znači i potrebu pregovora pojedinih država kandidata s Eurostatom o prihvaćanju regionalizacije države na razini NUTS II regija. Postoje brojni slučajevi odstupanja u europskim NUTS II regijama, bilo da broje manje od 800.000 stanovnika, bilo više od 3.000.000, kako kod novih, tako i kod starih članica gdje češće postoje iznimke.

Od analiziranih osam varijanti statističke regionalizacije, njih pet zadovoljava propisane preporuke Eurostata o minimalnom, odnosno o maksimalnom broju stanovnika za NUTS II regije. U ostale tri varijante (varijante **2, 5 i 7**) taj uvjet nije nominalno zadovoljen, ali je odstupanje minimalno. Naime, Grad Zagreb izdvojen je kao samostalna regija, koja je brojem stanovnika blago ispod propisanog minimuma. **Grad Zagreb prema propisima o lokalnoj i područnoj (regionalnoj) samoupravi istovremeno ima i status grada i županije, što predstavlja specifičan administrativni status, pa bi ga stoga bilo moguće izdvojiti kao samostalnu NUTS II regiju.** Standardna devijacija odstupanja broja stanovnika i omjer regije s najvećim i najmanjim brojem stanovnika ne odstupaju od uobičajenih vrijednosti u EU25 (Tablica 16).

Kod **očekivanog priljeva iz EU fondova**, u skladu s projekcijama regionalnog razvitka, jedino podjela na dvije regije (varijanta 8) do 2015. godine ostavlja mogućnost da sve regije imaju pravo na EU strukturne fondove u okviru cilja konvergencije (BDP p.c. PPS < 75% EU25). U tom bi slučaju ukupno očekivana raspoloživa sredstva iznosila oko 8,2 milijarde kuna godišnje. **Varijante u kojima je Grad Zagreb izdvojen kao NUTS II regija omogućuju svim ostalim županijama (grupiranim u regije) mogućnost korištenja EU strukturnih fondova, ali ne i Gradu Zagrebu zbog visoke razine razvijenosti (> 75% prosjeka EU25).** U tom slučaju očekivana raspoloživa sredstva iznosila bi oko 6,7 milijardi kuna godišnje. **U svim ostalim varijantama Grad Zagreb zbog visoke relativne razvijenosti onemogućuje županijama koje su objektivno slabije pristup sredstvima iz EU fondova koja se zasnivaju na razini BDP p.c PPS pokazatelja.** U slučaju grupiranja županija u široko definiranu Središnju Hrvatsku (varijanta 4) gotovo bi polovina stanovništva Hrvatske 2015. godine živjela u regiji s gospodarskom razvijenošću

višom od 75% BDP p.c. PPS EU25 (EU27), čime bi im bio onemogućen pristup fondovima. To je slučaj i sa starim prijedlogom statističke regionalizacije Hrvatske (varijanta 6) koji ima upravo taj osnovni nedostatak i koji s financijskog stajališta nije prihvatljiv. **Iz toga proizlazi da ni jedna varijanta s velikom regijom, sa Gradom Zagrebom u sebi, nije dobra sa stajališta pristupa strukturnim EU fondovima.**

Treći je kriterij homogenost pojedine varijante statističke regionalizacije Hrvatske na NUTS II razini, koji ponajprije čini osnovicu za konzistentnu regionalnu politiku. Za razliku od prvog kriterija, broja stanovnika koji preporučuje Eurostat, **ovaj je kriterij potrebno uvažavati sa stajališta vlastitog nacionalnog interesa**, jer pruža dugoročnu osnovicu za brojne ekonomske politike (ekonomsku, fiskalnu, demografsku, socijalnu i slično). Homogenost je propitana cluster analizom ekonomske, demografske i socijalne strukture. Ta je analiza ponudila jak argument za izdvajanje Grada Zagreba u samostalnu NUTS II regiju. Analiza svih varijanti regionalizacije pokazuje da je homogenost između Grada Zagreba i njegova okruženja izrazito slaba i ne bi ga bilo preporučljivo grupirati sa drugim županijama. Po gospodarskoj i demografskoj strukturi Grad Zagreb sličniji je pojedinim županijama Jadranske Hrvatske, a osobito najrazvijenijima – Istarskoj i Primorsko-goranskoj s kojima nije prostorno povezan.

Cluster analiza homogenosti upravo sugerira da se Grad Zagreb, s jedne strane, i Jadranska Hrvatska, s druge strane, izdvoje kao samostalne NUTS II regije. Najviša razina homogenosti ostvarena je grupiranjem županija u tri NUTS II regije, već spomenute, Grad Zagreb i Jadransku Hrvatsku, a treću čine sve ostale županije Kontinentalne Hrvatske (varijanta 2, odnosno varijanta 5 u nešto manjoj mjeri). **Prema kriteriju homogenosti relativno zadovoljavajući rezultat može se ostvariti statističkom regionalizacijom prikazanom u varijanti 7 sa četiri regije.** U toj su varijanti ponovo Grad Zagreb i Jadranska Hrvatska samostalne NUTS II regije, a ostale su županije podijeljene u dvije regije: Središnju i Istočnu Hrvatsku.

Tablica 16.

ZBIRNI REZULTATI RAZLIČITIH VARIJANTI STATISTIČKE REGIONALIZACIJE HRVATSKE NA NUTS II
RAZINI

Varijanta	Kriterij broja stanovnika (800.000 - 3.000.000)	Očekivana ukupno raspoloživa godišnja sredstva iz EU strukturnih fondova 2015. godine	Kriterij homogenosti	Prosječno odstupanje u indeksnim bodovima			Omjer regija s najvećim udjelom u ukupnom BDP / regija s najmanjim udjelom u ukupnom BDP 2015. godine	Omjer najrazvijenija / najnerazvijenija regija mjereno BDP p.c. PPS, 2003.
				površina	broj stanovnika	indeks BDP p.c. PPS, RH=100		
Varijante s tri NUTS II regije								
Varijanta 1	DA	6,1 mlrd HRK	NE	70,2	28,2	38,1	1,2	2,0 : 1
Varijanta 2	NE (vrlo blizu, 781.668)	6,7 mlrd HRK	DA	85,4	49,1	55,1	1,2	2,4 : 1
Varijanta 3	DA	4,5 mlrd HRK	NE	27,2	32,6	25,5	3,6	1,7 : 1
Varijanta 4	DA	4,3 mlrd HRK	NE	32,5	41,6	24,7	4,4	1,7 : 1
Varijanta 5	NE (vrlo blizu, 781.668)	6,7 mlrd HRK	DJELOMIČNO	83,7	44,6	55,5	1,1	2,4 : 1
Varijante sa četiri NUTS II regije								
Varijanta 6	DA	6,1 mlrd HRK	NE	61,3	20,6	35,4	2,9	2,2 : 1
Varijanta 7	NE (vrlo blizu, 781.668)	6,7 mlrd HRK	DJELOMIČNO	70,5	24,9	49,9	2,1	2,6 : 1
Varijante sa dvije NUTS II regije								
Varijanta 8	DA	8,2 mlrd HRK	NE	0,2	41,3	7,4	2,0	1,1 : 1

Od ostalih značajnih pokazatelja valja izdvojiti **omjer udjela između regije s najvećim i najmanjim udjelom BDP u ukupnom BDP Hrvatske**. Ovaj pokazatelj govori kolika je razlika u gospodarskoj snazi pojedinih regija, kao osnovi za preuzimanje funkcija u očekivanom procesu dalje decentralizacije aktivnosti javne uprave. Što je omjer manji (bliže 1), to je gospodarska snaga između regija ujednačenija. U tome analizirane varijante 1, 2 i 5 ukazuju na vrlo ujednačenu regionalnu snagu pojedinih regija mjerenu udjelom u BDP, a varijante 3, 4 i 6 ukazuju na izrazito velike razlike u ekonomskoj snazi pripadajućih regija. Posebno je problematična varijanta 4 (tri regije) s izrazitom heterogenošću ekonomske snage. Središnja Hrvatska s uključenim Gradom Zagrebom doseže 56% ukupnog hrvatskog BDP, a sa druge je strane ekstremno slučaj Istočne Hrvatske s manje od 14% ukupnog BDP. U takvim bi uvjetima proces dalje fiskalne decentralizacije doveo do nemogućnosti odgovarajućeg financijskog praćenja decentraliziranih funkcija, pa bi isto tako rezultirao nižom razinom kvalitete javnih usluga, prije svega djelatnosti zdravstva i obrazovanja, u kojima se očekuje još snažniji proces decentralizacije funkcija.

Pokazatelji omjera između najrazvijenije i najnerazvijenije regije usko su povezani s pokazateljem prosječnog odstupanja indeksa BDP p.c. PPS. U varijantama u kojima je omjer između najrazvijenije i najnerazvijenije regije veći, u pravilu je veća i standardna devijacija indeksa BDP. Tako su varijante s najvećim omjerom (varijanta 2, 5 i 7) istovremeno i varijante s najvećom standardnom devijacijom indeksa BDP. To su sve varijante u kojima je Grad Zagreb izdvojen kao samostalna NUTS II jedinica, pa svojom relativno dobrom razvijenošću povećava navedeni omjer na 2,4 odnosno 2,6. Takvi su omjeri usporedivi, kako s onima koje nalazimo u usporedbi s novim članicama - NMS, tako i u usporedbi sa starim članicama EU15 i mogu se smatrati prihvatljivima. Varijanta s podjelom na dvije regije (varijanta 8) iskazuje omjer između najrazvijenije i najnerazvijenije regije od samo 1,1, čime se otežava identifikacija područja kojima je pomoć objektivno potrebna i onemogućuje vođenje aktivnije regionalne politike.

Kao zaključak se kod statističke podjele na tri regije može utvrditi da je odnos prednosti i nedostataka najpovoljniji kod varijante 2 i varijante 5.

Kad govorimo o varijanti 2, uz pretpostavku da Eurostat može opravdati i prihvatiti izdvajanje Grada Zagreba kao administrativne jedinice koja je bitno različita od okruženja prema gospodarskoj strukturi, i u kojoj je broj stanovnika neznatno manji od minimalne granice, valja reći da ova varijanta ima prednost u odnosu na ostale zbog:

- izražene intraregionalne homogenosti i interregionalne heterogenosti,
- očekivanog višeg iznosa raspoloživih sredstava iz EU fondova u odnosu na druge varijante (osim varijante 8),
- ujednačene gospodarske snage regija,

- omjera između najrazvijenije i najnerazvijenije regije koji nije prevelik u odnosu na druge zemlje iz okruženja, a istovremeno omogućuje jasno formuliranje regionalne politike.

Varijanta 5 dijeli većinu prednosti s varijantom 2, uz iznimku da je intra-regionalna homogenost nešto slabija, ali je uravnoteženost broja stanovnika i ekonomske snage bolja.

Ostale varijante, **varijanta 1** u odnosu na varijantu 2 ima prednost u tome što se po broju stanovnika u **potpunosti uklapa** u Eurostatove kriterije, no **nedostatak joj je znatno niža razina gospodarske homogenosti i manji očekivani iznos sredstava iz EU strukturnih fondova**. Ta varijanta udovoljava napatku o broju stanovnika, ali je s nacionalnog stajališta, kako u učinkovitoj gospodarskoj politici, tako i po financijskim učincima u odnosu na strukturne fondove, **teško prihvatljiva**.

Varijante 3 i 4 ispunjavaju preporuku o broju stanovnika, no **nedostatak im je također heterogenost gospodarske strukture, znatno manja očekivana sredstva iz strukturnih fondova EU i izrazito visoke razlike u gospodarskoj snazi na taj način formiranih regija**. Naime, Grad Zagreb sa širim okruženjem u ovim varijantama čini Središnju Hrvatsku, pa bi gospodarska snaga takve regije 2015. godine bila 3,6, odnosno 4,4 puta veća od gospodarske snage Istočne Hrvatske, čime bi se znatno smanjila mogućnost nastavka procesa fiskalne decentralizacije. Stoga se varijante 3 i 4 čine **neprihvatljivima**, čak više nego varijanta 1.

Kod varijanti sa četiri regije analizirane su dvije varijante (**varijante 6 i 7**). Jedna je stari prijedlog DZS (varijanta 6), a druga je modificirana tako da je Grad Zagreb izdvojen kao samostalna jedinica, a Istočna je Hrvatska zbog uočene homogenosti proširena Bjelovarsko-bilogorskom županijom (varijanta 7).

Dobra je strana starog prijedloga DZS jedino to što je prema kriteriju broja stanovnika neupitno prihvaćen od strane Eurostata. Nedostatak u odnosu na sve varijante sa trima regijama i na varijantu 7 jest manja razina gospodarske homogenosti, jednako kao i manji očekivani iznos raspoloživih sredstava u okviru EU fondova. To je rezultat činjenice da Grad Zagreb sa sobom "povlači" cijelu Zagrebačku županiju iznad kriterija 75% BDP p.c. PPS EU25(27). Kad bi bila riječ o iznadprosječno razvijenom dijelu Hrvatske, to bi bilo uz određene ograde prihvatljivo, ali se tu radi o županiji koja je na razini razvijenosti od oko 70% prosjeka Hrvatske i takvo rješenje nije dugoročno dobro.

Varijanta 7 (4 regije) iskazuje zadovoljavajuće osrednju razinu homogenosti i jednako visok udio populacije koji će se naći na manje od 75% prosjeka BDP p.c PPS EU25 (kao i varijante 2 i 5). Određeni se nedostatak ove varijante pokazuje u izraženoj neravnomjernosti regionalne razine razvijenosti mjere- no BDP p.c. PPS i iznosi 2,6, a to je najviši omjer od osam varijanti. Kao i u ostalim varijantama, gdje je Grad Zagreb izdvojen kao samostalna NUTSII regija,

i ova varijanta pretpostavlja pregovore s Eurostatom o prihvaćanju Grada Zagreba kao samostalne NUTS II regije.

Potencijalna statistička regionalizacija Hrvatske na dvije NUTS II regije (**varijanta 8**), **osigurava zadovoljavanje kriterija broja stanovnika i maksimalan iznos potencijalnih sredstava** iz EU fondova. No, nedostaci su te varijante **izrazito nedovoljna razina interregionalne heterogenosti i intraregionalne homogenosti** (Grad Zagreb po svojim karakteristikama izdvaja se od ostalih županija kontinentalne regije). Dalje, zbog heterogenosti ukupnog hrvatskog prostora **ova varijanta nudi dvije velike regije i značajno otežava formuliranje i praćenje učinaka regionalne politike. Ona bi vjerojatno državnoj administraciji bila prihvatljiva zbog očekivanog financijskog učinka, ali stručna analiza ukazuje na nekvalitetnu osnovicu koju bi ta varijanta predstavljala za dugoročno vođenje regionalne politike.**

Što je nedvojbeno jasno, a što sporno za konačnu varijantu izbora regionalizacije Hrvatske?

Nedvojbeno je jasno da **Jadranska Hrvatska, koja obuhvaća sve županije koje imaju pristup moru, prema svim kriterijima predstavlja dobro rješenje za formiranje zasebne NUTS II regije.** Ovako definirana regija zadovoljava Eurostatove kriterije minimalnog i maksimalnog broja stanovnika, gospodarska je struktura u velikoj mjeri homogena, a prema dosegnutoj razini razvitka u terminima BDP p.c. PPS imat će pravo na financijsku potporu iz fondova EU u okviru programa konvergencije ne samo do projicirane 2015. godine, već za puno duže razdoblje.

Grad Zagreb prema svim karakteristikama predstavlja područje značajno različito od svog užeg i šireg okruženja. Razina razvijenosti, struktura gospodarstva, visoki fiskalni potencijal i financijska neovisnost, obrazovna struktura i karakteristike velikog grada ključna su obilježja koja govore u prilog izdvajanju Grada Zagreba u samostalnu NUTS II regiju (varijante 2, 5 i 7). Iako je po broju stanovnika Grad Zagreb (781,668) trenutno blago ispod preporučene minimalne granice koju Eurostat postavlja u slučaju kad se statistička regionalizacija NUTS II razine radi grupiranjem administrativnih jedinica, u okviru dogovora sa stručnjacima Eurostata kao argument za izdvajanje Grada Zagreba kao samostalne jedinice potrebno je navesti sljedeće:

- *Grad Zagreb predstavlja jedinstvenu administrativnu jedinicu koja istovremeno obnaša funkcije grada i županije, pa se stoga može izdvojiti kao zasebna NUTS II regija,*

- *Grad Zagreb prema ekonomskim, fiskalnim i obrazovnim kriterijima značajno je različit od svog okruženja, a županije iz okruženja Grada Zagreba prema svojim su karakteristikama daleko homogenije sa cjelokupnim područjem Kontinentalne Hrvatske, nego s Gradom Zagrebom. Grupiranje Grada Zagreba s nekim drugim županijama otežalo bi dugoročno vođenje kvalitetne regionalne politike,*
- *svojom veličinom po broju stanovnika i ekonomskoj snazi, u svim varijantama statističke regionalizacije, Grad Zagreb ima dominantnu ulogu, te bi županije grupirane zajedno s Gradom Zagrebom izgubile pravo na sredstva iz razvojnih fondova EU, iako je njima objektivno takva potpora potrebna, što je sa stajališta nacionalnih interesa neprihvatljivo,*
- *odstupanje od minimalne granice broja stanovnika je vrlo malo (oko 18.000 ljudi ili oko 2,3%), a može se očekivati da zbog razvojnog potencijala koji Grad Zagreb ima i migracijski saldo bude pozitivan, pa se krajem projekiranog razdoblja to odstupanje još više smanji. Dalje, u Grad Zagreb dnevno migrira na posao najmanje 40 tisuća ljudi (ne računajući migracije studenata i učenika, sustav predstavničkih inozemnih tijela i slično, koji nisu metodološki obuhvaćeni u popisu stanovništva kao rezidenti). Stoga Grad Zagreb kao ekonomska cjelina, uz 781 tisuću rezidenata, u svakodnevnom životu broji najmanje 820 tisuća ljudi,*
- *izdvajanje Grada Zagreba kao samostalne NUTS II jedinice ne bi bio nikakav presedan u formiranju regija novih članica EU (primjer izdvajanja Bratislave kao samostalne jedinice u Slovačkoj, pojedinih bugarskih i poljskih regija, cjelokupne Litve), a kod starih članica je situacija odstupanja od preporučenog minimalnog/maksimalnog broja stanovnika još učestalija,*
- *Grad Zagreb, već u ovom trenutku ima ustrojen odgovarajući statistički sustav koji bez većih napora, u organizacijskom i stručnom smislu, može osigurati kvalitetno prikupljanje podataka za tu razinu NUTS II regije, jednako kao i seriju povijesnih statističkih podataka.*

Pri grupiranju županija Kontinentalne Hrvatske u NUTS II regije preostaju dvije mogućnosti:

- grupiranje svih ostalih županija u jednu NUTS II regiju, Kontinentalnu Hrvatsku, čime se zadovoljavaju kriteriji broja stanovnika, homogenosti i mogućnost korištenja fondova EU u okviru programa konvergencije (**varijanta 2 i varijanta 5**) i
- razdvajanje na dvije regije, Središnju i Istočnu Hrvatsku, čime se također zadovoljava kriterij broja stanovnika i mogućnosti korištenja fondova EU, ali je interregionalna heterogenost i intraregionalna homogenost u tom slučaju manja. Pri razdvajanju na te dvije regije valja voditi računa o tome da je Bjelovarsko-bilogorska županija po svojim karakteristikama homogenija s područjem Istočne Hrvatske, nego s područjem Središnje Hrvatske (**varijanta 7**).

Ako se naglasak u potpunosti stavi na očekivane financijske učinke, a zanemare se kriteriji homogenosti i mogućnosti vođenja konzistentne regionalne politike, nego se ustraje u potpunosti na bottom up pristupu, tada se **varijanta 8** (podjela na dvije NUTS II regije) nameće kao rješenje. Kratkoročno gledano, ta se varijanta čini prihvatljivom, jer ne dovodi u pitanje Eurostatov minimalan-maksimalan kriterij broja ljudi i ne zahtijeva pregovore o strukturi hrvatskih NUTS II regija. No, zbog nesposobnosti i brojnosti najmanjih lokalnih jedinica (praktično općina) da u ovom trenutku generiraju i valoriziraju razvojne programe i zbog razine složenosti problema s kojima se pojedine od njih susreću, ona može imati dugoročno negativne učinke na razvitak Hrvatske. Filozofija razvitka varijante 8 u potpunosti podrazumijeva bottom-up regionalnu politiku razvitka za koju Hrvatska nema preduvjete (fiskalne, ljudske, institucionalne).

Očito je da postojeća varijanta regionalizacije (varijanta 6 – četiri regije) ne osigurava optimalan financijski učinak u odnosu na strukturne fondove, niti zadovoljava uvjet homogenosti kao osnovice za vođenje regionalne politike. Slično vrijedi i za varijantu 1 (tri regije) koja je jednaka po financijskim učincima i neznatno je homogenija od varijante 6.

Ostale varijante regionalizacije (2, 5 i 7) imaju bolji očekivani financijski učinak od postojeće varijante regionalizacije, ali zahtijevaju određeni napor u smislu pregovora s Eurostatom o ishođenju Gradu Zagrebu statusa NUTS II regije. Varijante 2, 5 i 7 zadovoljavaju uvjete homogenosti i pružaju dugoročno dobru osnovicu za vođenje konzistentne regionalne politike. Varijante statističke regionalizacije (3 i 4) s velikom središnjom regijom oko Grada Zagreba stvaraju probleme u pravu na povlačenje financijskih sredstava iz strukturnih fondova, jer Grad Zagreb svojom razvijenošću diže cijelu regiju na više od 75% BDP p.c. EU25 po paritetu kupovne snage. Ovisno o varijanti statističke regionalizacije i o postojanju regije s BDP p.c. više od 75% prosjeka EU 25 usložnjava se procedura povlačenja sredstava, jer će postojati dvije odvojene procedure unutar cilja konvergencije. Jedino varijanta 8 (dvije regije) osigurava postojanje samo jedne procedure. Odabir optimalne varijante statističke regionalizacije Hrvatske očito ima brojne druge značajne aspekte, osobito financijske, dugoročne razvojne, pa i političke, koji izlaze iz okvira “obične statističke podjele”.

LITERATURA

1. Aldenderfer, M. S., Blashfield, R. K. (1984). *Cluster Analysis: Quantitative Applications in the Social Sciences*. London: SAGE Publications.
2. Annual Work Programme for Grants 2005 for Enlargement. http://europa.eu.int/comm/enlargement/work_pgr_2005/index.htm

3. Arbia, G., Basile, R., Piras, G. (2004). "Using Spatial Panel Data Models in Modelling of Regional Growth and Convergence", Seminar on Spatial Econometrics, Zaragoza, Spain.
4. Council Regulation on Laying Down General Provisions on the European Regional Development Fund (2004). The European Social Fund and the Cohesion Fund, COM 492 final, Bruxelles.
5. Državni zavod za statistiku: različite publikacije i interni metodološki materijali.
6. Državni zavod za statistiku (2002). Projekt Nomenklatura prostornih jedinica za statistiku, Zagreb.
7. Državni zavod za statistiku (2005). Metodologija za uvođenje nacionalne klasifikacije prostornih jedinica za statistiku u statistički sustav Republike Hrvatske, Zagreb.
8. Državni zavod za statistiku (2001). Popis stanovništva, kućanstava i stanova 31. ožujka 2001. Web stranica. <http://www.dzs.hr/Popis%202001/popis20001.htm>
9. Državni zavod za statistiku (2002). Projekt Nomenklatura prostornih jedinica za statistiku (dokument Radne grupe, 2002.), Zagreb.
10. European Commission (2003). Council Regulation (EC) No. 1287/2003 on the Harmonisation of Gross National Income at Market Prices (GNI Regulation).
11. European Regional Statistics – Reference Guide (2002). Eurostat. Web stranica. <http://europa.eu.int/comm/eurostat>.
12. European Regional Statistics – Reference Guide (2003). Eurostat. Web stranica. http://www.eu-datashop.de/download/DE/klassif/ncronos/thema1/reg_guid.pdf
13. Europski sustav nacionalnih računa, ESA 1995 (1996). Commission of the European Communities, Luxembourg.
14. Eurostat (1995). Regional Accounts Methods Gross Value-Added and Gross Fixed Capital Formation by Activity, Luxembourg.
15. Eurostat, Statistics in focus (2003). Regional Gross Domestic Product in the European Union 2000. Web stranica. http://www.eu-datashop.de/download/EN/sta_kurz/thema1/dn_03_01.pdf
16. Eurostat, Statistics in Focus (2003). Regional Gross Domestic Product in the Candidate Countries. Web stranica. http://www.eu-datashop.de/download/EN/sta_kurz/thema1/dn_03_02.pdf
17. Eurostat Candidate Country Exhaustiveness Project (2002). General Guidelines, Annex A-F Candidate Country Studies and Reports.

18. Everitt, B. S., Landau, S., Leese, M. (2001). *Cluster Analysis*, 4th edition, London: Arnold Publishers.
19. Farrel, M. (2004). "Regional Integration and Cohesion – Lessons from Spain and Ireland in the EU", *Journal of Asean Economics*, No 14, pp. 927-946.
20. Hierarchical List of the Nomenclature of Territorial Units for Statistics-NUTS and the Statistical Regions of Europe, www.europa.eu.int/comm/eurostat/ramon/nuts
21. Human Development Report Croatia (2002). UNDP, Sveučilišna tiskara d.o.o., Zagreb.
22. Kaufman, L., Rousseeuw, P. J. (2005). *Finding Groups in Data: An Introduction to Cluster Analysis*, 2nd edition, New York: Wiley-Interscience.
23. Lovrinčević, Ž., Mikulić, D., Galić Nagyszombat, A. (2005). "Estimate of the Size of the Underground Economy in Croatia and the Impact on the Macroeconomic Policy", *6th International Conference: Enterprise in Transition*, Bol, Croatia.
24. Mikulić, D., Lovrinčević, Ž. (ur.) (2002). Eksperimentalni skup tekućih računa RH po sektorima nacionalnog gospodarstva za 1999. i 2000. godinu, Ekonomski institut, Zagreb i Državni zavod za statistiku RH, Zagreb.
25. Mikulić D, Lovrinčević Ž. (ur.) (2001). Uvođenje i primjena sustava nacionalnih računa, Istraživanja u 2001. godini, Ekonomski institut, Zagreb i Državni zavod za statistiku RH, Zagreb.
26. Mikulić D, Lovrinčević Ž. (ur.) (2004). Uvođenje i primjena sustava nacionalnih računa, II faza istraživanja u 2004. godini, Ekonomski institut, Zagreb i Državni zavod za statistiku RH, Zagreb.
27. Mikulić D, Lovrinčević Ž. (ur.) (2005). Uvođenje i primjena sustava nacionalnih računa – obuhvat nacionalnih računa za 2002. i 2003. godinu za Hrvatsku, druga faza, istraživanja za 2005. godinu, Zagreb.
28. Program statističkih istraživanja RH za 2000. do 2002. (2000). Narodne novine, broj 66.
29. Rašić, I. (2005). Primjena faktorske i cluster analize u grupiranju jedinica lokalne samouprave odabranih županija na temelju društveno-gospodarskih pokazatelja, magistarski rad, Zagreb.
30. Regulation (EC) No 1059/2003 of the European Parliament and of the Council of 26 May 2003 on the establishment of a common classification of territorial units for statistics (NUTS) (Official Journal L 154, 21/06/2003). Web stranica. http://europa.eu.int/eur-lex/pri/en/oj/dat/2003/l_154/l_15420030621en00010041.pdf
31. SAPARD Annual Report Year 2002 (2003). COM 582 Final.

32. Sporazum o stabilizaciji i pridruživanju između Republike Hrvatske i EU (2001).
33. The European Structural Funds: A Solidarity Policy. http://europa.eu.int/comm/regional_policy/atlas/factsheets/pdf/fact_eu25_en.pdf34.
The Mini ISPA Report 2000-2003 (2004). DG Regio ISPA.
35. Treaty Establishing the European Economic Community (1957). http://europa.eu.int/eur-lex/lex/en/treaties/treaties_founding.htm
36. Marinović-Uzelac, A. (2001). "Prostorno planiranje", *Dom i svijet*.
37. WIIW Research Report No. 308.
38. Web http://europa.eu.int/comm/agenda2000/index_en.htm
39. Web <http://europa.eu.int/scadplus/leg/en/lvb/l60013.htm>
40. Web <http://www.europa.eu.int/comm/enlargement>
41. Web <http://www.europa.eu.int/scadplus/leg/en/lvb/l60014.htm>
42. Web <http://epp.eurostat.cec.eu.int>
43. Web http://www.europa.eu.int/comm/regional_policy/funds/ispa/enlarge_en.htm
44. Web http://europa.eu.int/comm/eurostat/ramon/nuts/statistical_regions_en.html
45. Web http://europa.eu.int/comm/eurostat/ramon/nuts/codelist_en.cfm
46. Web http://www.europa.eu.int/comm/regional_policy/funds/prord/

HOW TO REGIONALIZE CROATIA OPTIMALLY?

Summary

This paper questions the choice of the optimal variable of the statistical regionalization of Croatia on the NUTS II level. The choice criteria are the following: Eurostat population number, maximum financial effects gained from structural fund access in the long term and the criteria of homogeneity of specific regions as the basis for consistent, long term regional development policy. The authors examine the eight alternatives of statistical regionalization and demonstrate the implications for Croatia, from the financial and development viewpoint. The tested alternatives were the statistical regionalization with two, three and four NUTS II regions and all of the advantages and disadvantages for each of the examined variables. In continuation, the authors question the link between the regional policy approach (bottom-up and top-down) and the suitability of the specific choice of statistical regions for regional policy management in Croatia.

Key words: regionalization, Croatia, EU structural funds